

UNIVERZITA PARDUBICE

FAKULTA EKONOMICKO-SPRÁVNÍ

DIPLOMOVÁ PRÁCE

2022

Bc. Pavlína Urválková

Univerzita Pardubice
Fakulta ekonomicko-správní

Bankrotní predikční modely po roce 2015
Diplomová práce

2022

Bc. Pavlína Urválková

Univerzita Pardubice
Fakulta ekonomicko-správní
Akademický rok: 2021/2022

ZADÁNÍ DIPLOMOVÉ PRÁCE (projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Pavína Urválková**
Osobní číslo: **E20758**
Studijní program: **N0413A050009 Ekonomika a management**
Studijní obor: **Ekonomika a management podniku**
Téma práce: **Bankrotní predikční modely po roce 2015**
Zadávající katedra: **Ústav podnikové ekonomiky a managementu**

Zásady pro vypracování

Cílem práce je analyzovat celosvětový vývoj v tvorbě bankrotních modelů od roku 2015, zhodnotit současný stav a ověřit funkčnost vybraných modelů v podmínkách ČR s využitím různých metod pro kvantifikaci jejich predikční schopnosti.

Osnova:

- Vymezení základních pojmů
- Vývoj v tvorbě bankrotních modelů od roku 2015
- Funkčnost vybraných modelů v podmínkách ČR
- Zhodnocení predikční schopnosti vybraných modelů

Rozsah pracovní zprávy: **cca 50 stran**
Rozsah grafických prací:
Forma zpracování diplomové práce: **tištěná/elektronická**

Seznam doporučené literatury:

ALTMAN, Edward I., Edith HOTCHKISS a Wei WANG. *Corporate Financial Distress, Restructuring, and Bankruptcy: Analyze Leveraged Finance, Distressed Debt, and Bankruptcy*. 4th ed. Hoboken: John Wiley, c2019, 349p. ISBN 978-1-119-48181-2.
CHAUDHURI, Arindam a Soumya K. GHOSH. *Bankruptcy Prediction through Soft Computing based Deep Learning Technique*. Singapore: Springer Nature, c2017, 102p. ISBN 978-981-10-6683-2.
KALOUDA, František. *Finanční analýza a řízení podniku*. 3. rozšířené vydání. Plzeň: Vydavatelství a nakladatelství Aleš Čeněk, 2017. 328s. ISBN 978-80-7380-646-0.
KNÁPKOVÁ, Adriana, Drahomíra PAVELKOVÁ, Daniel REMEŠ a Karel ŠTEKER. *Finanční analýza: komplexní průvodce s příklady*. 3., kompletně aktualizované vydání. Praha: Grada Publishing, 2017. 228s. Prosperita firmy. ISBN 978-80-271-0563-2.
VOCHOZKA, Marek. *Metody komplexního hodnocení podniku*. 2. aktualizované vydání. Praha: Grada Publishing, 2020. 479s. Finance. ISBN 978-80-271-1701-7.

Vedoucí diplomové práce: **Ing. Michal Kuběnka, Ph.D.**
Ústav podnikové ekonomiky a managementu

Datum zadání diplomové práce: **1. září 2021**
Termín odevzdání diplomové práce: **30. dubna 2022**

prof. Ing. Jan Stejskal, Ph.D. v.r.
děkan

L.S.

Ing. Michaela Kotková Stříteská, Ph.D. v.r.
vedoucí ústavu

V Pardubicích dne 1. září 2021

Prohlašuji:

Práci s názvem Bankrotní predikční modely po roce 2015 jsem vypracovala samostatně. Veškeré literární prameny a informace, které jsem v práci využila, jsou uvedeny v seznamu použité literatury.

Byla jsem seznámena s tím, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, zejména se skutečností, že Univerzita Pardubice má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 autorského zákona, a s tím, že pokud dojde k užití této práce mnou nebo bude poskytnuta licence o užití jinému subjektu, je Univerzita Pardubice oprávněna ode mne požadovat přiměřený příspěvek na úhradu nákladů, které na vytvoření díla vynaložila, a to podle okolností až do jejich skutečné výše.

Beru na vědomí, že v souladu s § 47b zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů (zákon o vysokých školách), ve znění pozdějších předpisů, a směrnici Univerzity Pardubice č. 7/2019 Pravidla pro odevzdávání, zveřejňování a formální úpravu závěrečných prací, ve znění pozdějších dodatků, bude práce zveřejněna prostřednictvím Digitální knihovny Univerzity Pardubice.

V Pardubicích dne 30. 4. 2022

Pavλίna Urválková v.r.

PODĚKOVÁNÍ:

Tímto bych ráda poděkovala svému vedoucímu diplomové práce panu Ing. Michalu Kuběnkovi, Ph.D. za jeho odbornou pomoc, cenné rady a poskytnuté materiály, které mi pomohly při zpracování diplomové práce. Dále bych chtěla poděkovat rodině a přátelům za podporu.

ANOTACE

Předmětem této diplomové práce je analýza současného stavu bankrotních modelů od roku 2015 a využití vybraných predikčních modelů v podmínkách České republiky. Teoretická část se zabývá finanční tísní a dalšími znaky, které souvisejí s úpadkem, problematikou bankrotních modelů a metodami kvantifikace jejich přesnosti. Dále je zde uveden stručný vývoj bankrotních modelů od roku 2015. V praktické části se testují tři vybrané modely na souboru podniků ze zpracovatelského průmyslu a určuje se jejich přesnost třemi metodami. Na závěr je uvedeno zhodnocení získaných výsledků.

KLÍČOVÁ SLOVA

bankrotní modely, finanční tíseň, úpadek, metody kvantifikace, predikční schopnost

TITLE

Bankruptcy prediction models after 2015

ANNOTATION

The subject of this diploma thesis is the analysis of the current state of bankruptcy models since 2015 and the use of selected prediction models in the conditions of the Czech Republic. The theoretical part deals with financial distress and other signs of bankruptcy, bankruptcy models and methods of quantifying their accuracy. Furthermore, there is a development of bankruptcy models since 2015 briefly described. In the practical part, there are three selected models tested on a set of companies from the manufacturing industry. Their accuracy is determined by three methods. Finally, there is an evaluation of the obtained results mentioned.

KEYWORDS

bankruptcy models, financial distress, bankruptcy, quantification methods, predictive ability

OBSAH

ÚVOD.....	12
1 VYMEZENÍ ZÁKLADNÍCH POJMŮ	13
1.1 FINANČNÍ TÍSEŇ.....	13
1.2 BANKROTNÍ MODELY	17
1.3 METODY KVANTIFIKACE PREDIKČNÍCH SCHOPNOSTÍ	17
2 CELOSVĚTOVÝ VÝVOJ V TVORBĚ BANKROTNÍCH MODELŮ OD ROKU 2015....	21
2.1 VOCHOZKA, STRAKOVÁ A VÁCHAL 2015.....	21
2.2 SHIRINKINA A VALIULLINA 2015.....	22
2.3 JEŽOVITA 2015	22
2.4 NĚMEC, PAVLÍK 2016.....	23
2.5 ŠLEFENDORFAS 2016.....	24
2.6 DURICA A ADAMKO 2016.....	25
2.7 ALMAMY, ASTON A NGWA 2016.....	25
2.8 MIHALOVIČ 2016.....	26
2.9 ALAMINOS A KOL. 2016.....	27
2.10 HERMAN 2017.....	28
2.11 ALTMAN A KOL. 2017.....	29
2.12 ADAMKO, KLIEŠTIK A KOVÁČOVÁ, 2018	30
2.13 SVABOVA, DURICA A PODHORSKA 2018.....	31
2.14 KLIESTIK, VRBKA A ROWLAND 2018	31
2.15 JENČOVÁ, ŠTEFKO A VAŠANIČOVÁ 2020	33
2.16 OGACHI A KOL. 2020	34
2.17 VODA, DOBROTÁ A KOL. 2021	35
2.18 ADAMOWICZ A NOGA 2021	36
2.19 HORVÁTHOVÁ, MOKRIŠOVÁ A PETRUŠKA 2021	37
2.20 CINDIK A ARMUTLULU 2021	38
2.21 SFAKIANAKIS 2021	39
2.22 PŘEHLED OSTATNÍCH MODELŮ	39
2.23 ZHODNOCENÍ SOUČASNÉHO STAVU.....	43
3 FUNKČNOST VYBRANÝCH MODELŮ V ČR	44
3.1 DATA PODNIKŮ	44
3.2 ZPRACOVATELSKÝ PRŮMYSL DLE NACE	44
3.3 VYBRANÉ BANKROTNÍ MODELY	45
3.4 APLIKACE VYBRANÝCH MODELŮ NA DATA	47
3.4.1 Adamowicz a Noga (2021).....	47
3.4.2 Altman a kol. (2017).....	47
3.4.3 Ježovita (2015)	48
4 ZHODNOCENÍ PREDIKČNÍ SCHOPNOSTI VYBRANÝCH MODELŮ.....	50
4.1 ARITMETICKÝ PRŮMĚR SPRÁVNÉ KLASIFIKACE	50
4.2 MÍRA SPRÁVNÉ KLASIFIKACE (ACC)	52
4.2.1 Adamowicz a Noga (2021).....	52
4.2.2 Altman a kol. (2017).....	53
4.2.3 Ježovita (2015)	54
4.2.4 Porovnání modelů.....	55
4.3 ROC KŘIVKA.....	55
4.3.1 Adamowicz a Noga (2021).....	56
4.3.2 Altman a kol. (2017).....	56
4.3.3 Ježovita (2015)	57
4.3.4 Porovnání modelů.....	58
4.4 CAP KŘIVKA	59
4.4.1 Adamowicz a Noga (2021).....	59
4.4.2 Altman a kol. (2017).....	59
4.4.3 Ježovita (2015)	60
4.4.4 Porovnání modelů.....	61

4.5	CELKOVÉ ZHODNOCENÍ	61
4.5.1	Porovnání modelů s původní spolehlivostí.....	61
4.5.2	Zhodnocení kvantifikačních metod	62
ZÁVĚR.....	64
POUŽITÁ LITERATURA	66

SEZNAM ILUSTRACÍ A TABULEK

Tabulka 1: Hodnotící tabulka	18
Tabulka 2: Predikční bankrotní model Vochozka, Straková a Váchal.....	21
Tabulka 3: Predikční bankrotní model Němec a Pavlík	23
Tabulka 4: Predikční bankrotní model Durica a Adamko	25
Tabulka 5: Zpracovatelský průmysl dle CZ-NACE	45
Tabulka 6: Přehled poměrových ukazatelů v bankrotních modelech.....	46
Tabulka 7: Spolehlivost modelu Adamowicz a Noga pro bonitní podniky	47
Tabulka 8: Spolehlivost modelu Adamowicz a Noga pro bankrotní podniky	47
Tabulka 9: Spolehlivost modelu Altman a kol. pro bonitní podniky	48
Tabulka 10: Spolehlivost modelu Altman a kol. pro bankrotní podniky	48
Tabulka 11: Spolehlivost modelu Ježovita pro bonitní podniky	48
Tabulka 12: Spolehlivost modelu Ježovita pro bankrotní podniky	49
Tabulka 13: Hodnotící tabulka Adamowicz a Noga	52
Tabulka 14: Celková spolehlivost modelu Adamowicz a Noga	53
Tabulka 15: Hodnotící tabulka Altman a kol.	53
Tabulka 16: Celková spolehlivost modelu Altman a kol.	53
Tabulka 17: Hodnotící tabulka Ježovita	54
Tabulka 18: Celková spolehlivost modelu Ježovita	54
Tabulka 19: Porovnání vypočítané a původní spolehlivosti.....	62
Tabulka 20: Porovnání vypočítané a původní spolehlivosti hodnoty pod křivkou	62
Tabulka 21: Porovnání vybraných metod kvantifikace	62
Obrázek 1: Křivka ROC	19
Obrázek 2: Křivka CAP.....	20
Obrázek 3: Graf spolehlivosti modelů pro bonitní podniky (v %).....	50
Obrázek 4: Graf spolehlivosti modelů pro bankrotní podniky (v %).....	51
Obrázek 5: Graf aritmetického průměru spolehlivosti pro všechny podniky (v %).....	52
Obrázek 6: Graf míry správné klasifikace (v %).....	55
Obrázek 7: Grafické znázornění křivky ROC modelu Adamowicz a Noga.....	56
Obrázek 8: Grafické znázornění křivky ROC modelu Altman a kol.	57
Obrázek 9: Grafické znázornění křivky ROC modelu Ježovita	58
Obrázek 10: Graf porovnání hodnoty pod křivkou (AUC) u všech modelů	58
Obrázek 11: Grafické znázornění křivky CAP modelu Adamowicz a Noga.....	59
Obrázek 12: Grafické znázornění křivky CAP modelu Altman a kol.	60
Obrázek 13: Grafické znázornění křivky CAP modelu Ježovita.....	60
Obrázek 14: Graf porovnání hodnoty Accuracy ratio u všech modelů	61

SEZNAM ZKRATEK A ZNAČEK

ANN	Umělé neuronové sítě
ČR	Česká republika
DPH	Daň z přidané hodnoty
EAT	Čistý zisk
EBIT	Zisk před úroky a zdaněním
EU	Evropská unie
EVA	Ekonomická přidaná hodnota
HDP	Hrubý domácí produkt
kol.	kolektiv
LR	Logistická regrese
MDA	Vícenásobná diskriminační analýza
NACE	Klasifikace ekonomických činností
OKEČ	Odvětvová klasifikace ekonomických činností
Sb.	Sbírka zákonů
SK	Slovenská republika

ÚVOD

V současném nestabilním ekonomickém prostředí mohou mít podniky problémy nejen s konkurencí, ale i se svými dodavateli, zákazníky a zaměstnanci. Například rostoucí ceny, mzdové náklady nebo vládní opatření mohou mít negativní vliv na podnik. Včasné použití bankrotních modelů, může podnikům pomoci identifikovat blížící se finanční tíseň. Podniky díky tomu mohou včas zasáhnout a snažit se vyřešit problémové oblasti.

Bankrotní modely se neustále vyvíjí již od jednoduchých modelů založených na vícenásobné diskriminační analýze po složitější modely s použitím umělých neuronových sítí. Společnosti si mohou vybrat model, který bude vyhovovat jejich konkrétním podmínkám.

Cílem práce je analyzovat celosvětový vývoj v tvorbě bankrotních modelů od roku 2015, zhodnotit současný stav a ověřit funkčnost vybraných modelů v podmínkách ČR s využitím různých metod pro kvantifikaci jejich predikční schopnosti. Práce se dělí na čtyři hlavní kapitoly.

První kapitola se zaměřuje na finanční tíseň a s tím spojené znaky úpadku. Dále je zde úvod do problematiky bankrotních modelů a jsou zde popsány některé metody kvantifikace predikčních schopností modelů.

Druhá kapitola analyzuje vývoj nalezených a vybraných bankrotních modelů od roku 2015. Nejrozšířenější metody používané při tvorbě modelu jsou modely založené na vícenásobné diskriminační analýze a logistické regresi. U těchto modelů se navíc uvádí i vzorec výpočtu a vysvětlení proměnných. Druhou skupinou jsou modely vytvořené pomocí strojového učení. Nakonec je zhodnocení současného stavu.

V třetí kapitole se testují tři vybrané bankrotní modely na reálných podnikových datech v podmínkách České republiky. Modely se testují na datech od 172 podniků zpracovatelského průmyslu z České republiky, z toho bylo 115 bonitních a 57 bankrotních.

Ze získaných výsledků ze třetí kapitoly se v poslední čtvrté kapitole ověřuje predikční schopnost modelů pomocí tří vybraných metod kvantifikace. Cílem je ověření funkčnosti vybraných modelů pro data českých podniků a porovnání modelů mezi sebou.

1 VYMEZENÍ ZÁKLADNÍCH POJMŮ

V této kapitole jsou vysvětleny základní pojmy vztahující se k bankrotu.

1.1 Finanční tíseň

Finanční tíseň je situace, kdy podnik nemá dostatečné peněžní toky k pokrytí svých závazků a dochází k poklesu jeho tržní hodnoty. (Whitaker, 1999). Finanční tíseň je poměrně častým stavem podniků a neplatí, že musí znamenat zánik. Je to situace, kdy dochází k významnému poklesu klíčových ukazatelů výkonnosti buď z externích nebo interních důvodů. Například se může jednat o pokles tržeb, likvidity, ziskovosti či hodnoty podniku. Jevy bývají do značné míry souběžné nebo se vyvíjí jeden z druhého. (Schönfeld, 2018)

Symptomy blížící se finanční krize

Symptomy blížící se finanční krize podle Synka (2011) jsou klesající odbyt, růst zásoby hotových výrobků a rozpracované výroby, tím je zvyšována vázanost finančních prostředků. Společnost uhrazuje závazky se zpožděním. Ceny vstupů, mezd a úroky rostou, rentabilita tržeb i kapitálu tím klesá a dochází často ke ztrátovosti celého podniku. Výroba klesne pod bod zvratu. Likvidní zdroje jsou vyčerpány, podnik si půjčuje další peněžní prostředky a dluh roste. Věřitelé si žádají konkurz.

Pro předcházení úpadku společnosti jsou používány určité indikátory, které jsou součástí finanční analýzy. Nejdůležitějšími finančními indikátory jsou záporný vlastní kapitál a znepokojující hodnoty ukazatelů likvidity. První znamení možného úpadku předlužením nastává při záporných hodnotách vlastního kapitálu. Společnost je tak financována pouze cizími zdroji. Když hodnoty ukazatelů likvidity mají příliš nízké hodnoty, může nastat potíž hradit veškeré krátkodobé závazky. (Píša, 2019) V této souvislosti mohou banky zpřísnit úvěrové podmínky, aby zabránily riziku budoucího selhání, které může vést k dalším finančním problémům. Pokud firma bude mít vyšší úroveň likvidity bude to mít pozitivní vliv na udržení společnosti. (Brédart, 2014)

Příčiny krize jsou interní (subjektivní) a externí (objektivní). Mezi interní příčiny patří například chyby v řízení společnosti, problémy s likviditou, prodlužování doby úhrady závazků, odchod klíčových zaměstnanců, absence inovací, růst počtu reklamací a další faktory, které společnost může sama ovlivnit. Do externích příčin lze zahrnout faktory politické, ekonomické (fáze ekonomického cyklu), měnové, finanční, právní, daňové a sociální. Tyto faktory mají zásadní dopad na hospodářskou situaci podniku, ale podnik je nemůže sám ovlivnit. (Synek, 2011) V současné době pandemie COVID-19 hospodářská

politika EU velmi výrazně ovlivňuje současné politické aspekty, které působí na podniky. (Vochozka, 2021)

Podle Schönfelda (2018) je zánik podniku charakterizován zvětšováním některých existenčních problémů:

- nedostatečné cash flow (záporné cash flow)
- krize likvidity (žádná likvidní aktiva)
- platební neschopnost (insolventnost)
- předlužení (závazky převyšují majetek společnosti)

Bankrot

Bankrot je nepostradatelnou součástí fungování podniků v podmínkách tržního hospodářství. Na jedné straně je to normální, protože konkurence likviduje nerentabilní jednotky a vytváří prostor pro ty, kteří efektivněji využívají omezené zdroje. Na druhé straně má každý bankrot negativní dopad na mnoho zúčastněných stran, včetně věřitelů, dodavatelů, zaměstnanců a místní komunity. (Prusak, 2018)

Měření rizika bankrotu společností je jednou z hlavních výzev ekonomického a finančního výzkumu. V současné době, s rostoucí finanční globalizací a rychlejšími ekonomickými změnami, je zaměření na zvýšení spolehlivosti modelů prognózy a prodloužení horizontu předpovědi na 10 let před vyhlášením úpadku. (Korol, 2019)

Predikce bankrotu je přičítána různým aspektům finanční tísně v různých společnostech. Jeho významnost nastává, když si věřitelé a investoři vypočítají pravděpodobnost, že společnost může být v úpadku. (Chaudhuri a Ghosh, 2017) Důležité je provést predikci rizika bankrotu, protože včasné odhalení zhoršující se finanční situace, umožňuje přijetí nápravných opatření. Lze tím zabránit trvalým ztrátám současných nebo potenciálních poskytovatelů kapitálu. (Prusak, 2018)

Mezi faktory bankrotu patří i velikost firem. Menší struktury častěji narazí na překážky v jednání se svými partnery (zákazníky nebo dodavateli). Mají větší obtíže při hledání kapitálu, investicích do technologií, inovací, školení zaměstnanců atd. (Brédart, 2014)

Společnost se dostane do bankrotu, když její celkové závazky přesáhnou celková aktiva. Dokud firma nevyhlásí bankrot, je obtížné rozeznat, zda je v úpadku. (Altman, Hotchkiss a Wang, 2019)

V České republice se kromě pojmu bankrot používá také pojem úpadek. Rozlišuje se úpadek jako ekonomický stav podniku, kdy podnik je buď v platební neschopnosti nebo předlužen. Je to bez ohledu na to, zda byl tento stav promítnut do veřejného prohlášení soudem (ať z návrhu podniku nebo věřitele). Za druhé je úpadek jako soudem deklarovaný stav. (Schönfeld, 2018)

Podle zákona č. 182/2006 Sb., o úpadku a způsobech jeho řešení (insolvenční zákon) je dlužník v úpadku, pokud má více věřitelů, peněžité závazky po dobu delší 30 dnů, které jsou po lhůtě splatnosti, a není schopen tyto závazky plnit.

Platební neschopnost

Platební neschopnost nastává, když tvorba zisku a cash flow dlužníka nemají schopnost generovat dostatečnou hotovost na pokrytí splatných závazků. Platební neschopnost se rozlišuje na dočasnou, přechodnou nebo trvalou. Hlavní příčinou systémové platební neschopnosti, která souvisí s úpadkem, je nedostatečná tvorba zisku a cash flow. Snížená tvorba zisku, tím i vlastního kapitálu a hromadění závazků přerostou v předlužení podniku. Podnik je předlužený, pokud má dlužník více věřitelů a souhrn závazků převyšuje hodnotu jeho majetku. Při této situaci mají věřitelé ekonomickou kontrolu nad podnikem. (Schönfeld, 2018)

Selhání

Selhání v ekonomickém smyslu znamená, že realizovaná míra návratnosti investovaného kapitálu s přihlédnutím k riziku je výrazně nižší než běžné sazby u podobných investic. (Altman, Hotchkiss a Wang, 2019) Společnost může selhávat několik let, pokud není schopna splácet své současné dluhy. (Chaudhuri a Ghosh, 2017)

Insolvence

Insolvence je další termín, který zobrazuje negativní výkon firmy. (Altman, Hotchkiss a Wang, 2019) Naznačuje nedostatek likvidity a je důležitou silou při prohlášení o bankrotu. Nastává v situaci, když společnost nemůže uspokojit své finanční požadavky. (Chaudhuri a Ghosh, 2017) Může to být nedostatkem peněžního toku nebo nedostatkem likvidity. Lze to považovat jen za dočasný stav. Platební neschopnost je kritická, když se vztahuje na případy, kdy celkové závazky převyšují reálné ocenění celkových aktiv. Skutečné čisté jmění firmy je záporné. V některých zemích může nastat konkurzní řízení a rozhodnutí o platební neschopnosti. (Altman, Hotchkiss a Wang, 2019) Způsoby řešení úpadku dlužníka v insolvenčním řízení v České republice podle zákona č. 182/2006 Sb., o úpadku a způsobech

jeho řešení (insolvenční zákon), jsou konkurs, reorganizace, oddlužení a zvláštní způsoby řešení úpadku.

Neplacení dluhu

Neplacení dluhů se vyskytuje mezi dlužníkem a věřitelem, kdy dlužník porušuje smlouvu s věřitelem. Nesplnění dluhových závazků může vést k selhání. (Chaudhuri a Ghosh, 2017)

Nespolehlivost plátce DPH

Dle §106a zákona o DPH se plátce stává nespolehlivým, poruší-li závažným způsobem své povinnosti, které se vztahují ke správě daně. O nespolehlivém plátcovi rozhoduje správce daně. Situace, které se považují za závažné porušení, jsou objasněny v Informacích Generálního finančního ředitelství. Institut nespolehlivého plátce byl zaveden jako nástroj pro zlepšení výběru daní a jako boj s daňovými úniky v oblasti DPH. Institut nespolehlivého plátce má působit represivně (zveřejnění označení nespolehlivý plátce) a preventivně. Preventivní prvek je provázán s ručením dle §109 zákona o DPH. (Generální finanční ředitelství, 2017)

Exekuce

Exekuce, která je také označována jako výkon rozhodnutí, je proces za účelem vynucení splnění uložené povinnosti, pokud nebyla splněna dobrovolně. Věřitelé vymáhají dlužné částky od dlužníka, pokud nedošlo k dobrovolnému plnění ze strany dlužníka. (Schellová, 2008)

Likvidace společnosti

Likvidace společnosti je postup mimosoudního vyrovnání majetkových vztahů u právnické osoby, která zaniká. Likvidátor přebírá pravomoci statutárního orgánu společnosti v omezeném rozsahu. Cílem likvidace je ukončit činnosti podniku, rozprodání majetkových částí a ze získaných finančních prostředků uhradit závazky společnosti. (Vochozka a Mulač, 2012)

Zánik podniku

Se zánikem podniku se pojí dva pojmy, a to jsou zrušení a zánik. Zrušení společnosti je rozhodnutí o ukončení činnosti podniku. Zánik společnosti nastává v okamžiku výmazu z obchodního rejstříku. (Vochozka a Mulač, 2019) Ke zrušení podniku dochází buď na základě dobrovolného rozhodnutí vlastníka, nebo například na základě soudního rozhodnutí. (Synek, 2011)

1.2 Bankrotní modely

Bankrotní modely informují uživatele, zda je firma v dohledné době ohrožena bankrotem. Vychází se z předpokladu, že firma, která je ohrožena bankrotem, vykazuje před touto událostí typické symptomy bankrotu. Nejčastějšími problémy jsou oběžná likvidita, výše čistého pracovního kapitálu a rentabilita celkového vloženého kapitálu. (Růčková, 2019). Úkolem modelů predikce bankrotu je hledat vysvětlující faktory, identifikovat důvody, proč nastal bankrot. (Chaudhuri a Ghosh, 2017)

Z bankrotních modelů je jednoduchá prezentace výsledků. V rámci modelu se porovnává dosažená hodnota v rámci intervalu. Lze snadno poznat, zda je podnik schopen přežít případnou finanční tíseň, vyskytuje se v šedé zóně nebo je ohrožen bankrotem. (Vochozka, 2020)

Většina modelů zajišťuje optimální prediktivní schopnost, při kratším horizontu předpovědi, jejich přesnost se po třech letech výrazně snižuje. (Korol, 2019)

Klasické statistické metody byly dlouhou řadu let využívány k rozvoji jednorozměrných diskriminačních analýz. Metody využívaly nejrůznější postupy k rozdělení společností na selhávající a prosperující, s určitou mírou klasifikační chyby. Klasifikační chyba znamená, že zdravá společnost bude chybně klasifikována jako společnost nezdravá a naopak. Rozšířenější statistickou metodou je více rozměrná diskriminační analýza, dále logit analýza. Mezi další klasické metody patří jednorozměrná analýza, risk index modely, probit a logit analýza a lineární pravděpodobnostní modely. (Vochozka, 2020)

Existuje mnoho statistických metod založených na modelech predikce bankrotu. V dnešní době jsou populárnější metody využívající umělé inteligence, díky jejich dobré výkonnosti. Nejoblíbenější se stala metoda umělé neuronové sítě (ANN). (Zhao a kol., 2017)

1.3 Metody kvantifikace predikčních schopností

V této podkapitole jsou uvedeny kvantifikační metody k ověření predikční schopnosti modelů. K obecnému hodnocení pro libovolný binární model slouží hodnotící tabulka, která hodnotí aktuální stav podniků a jejich klasifikování bankrotním modelem.

Tabulka 1: Hodnotící tabulka

Aktuální stav	Klasifikace modelem	
	Bankrotní	Nebankrotní
Bankrotní	True Positives (TP)	ERROR I.
Nebankrotní	ERROR II.	True Negatives (TN)

Zdroj: zpracováno podle (Fawcett, 2006)

Výstupy tabulky:

- true positives – bankrotní podnik je správně klasifikovaný jako bankrotní
- true negatives – nebankrotní podnik je správně klasifikován jako nebankrotní
- chyba prvního druhu (ERROR I.) – bankrotní podnik je chybně klasifikován jako nebankrotní
- chyba druhého druhu (ERROR II.) – nebankrotní podnik je chybně klasifikován jako bankrotní

Vzorce pro výpočet míry správné klasifikace mají tvar:

$$TPR = \frac{TP}{TP + ERROR\ I.} \quad SPC = \frac{TN}{TN + ERROR\ II.} \quad (1)$$

$$ACC = \frac{TP + TN}{TP + TN + ERROR\ I. + ERROR\ II.} \quad (2)$$

TPR značí míru úspěšnosti predikce bankrotu pro finančně nestabilní podniky. SPC představuje míru úspěšnosti pro finančně stabilní podniky. ACC představuje míru správné klasifikace modelu. (Fawcett, 2006)


Křivka ROC (Receiver Operating Characteristic Curve) graficky zkoumá přesnost modelů, má schopnost oddělit pozitivní a negativní případy. Křivka ROC je užitečná při vyhodnocování prediktivních modelů. Oblast pod ROC křivkou zvaná AUC (Area under the ROC Curve), se používá jako měřítko přesnosti, může nabývat hodnot od 0,5 do 1. U modelu s perfektní rozlišovací schopností prochází křivka ROC levým horním rohem a AUC se rovná 1. Při hodnotě AUC 0,5 je model označený za náhodný a křivka ROC je diagonální od levého dolního rohu k pravému hornímu rohu. Čím větší je plocha pod křivkou ROC, tím lepší je

predikční schopnost modelu. Přesnost je měřena plochou pod křivkou ROC, která je hodnocena podle stupnice:

- 0,5 – 0,6 = neúčinný
- 0,6 – 0,7 = špatný
- 0,7 – 0,8 = uspokojivý
- 0,8 – 0,9 = dobrý
- 0,9 – 1 = vynikající

(Mehdi a kol., 2011)

Na obrázku je zobrazena křivka ROC, kde větší plocha pod křivkou (B) značí lepší model.



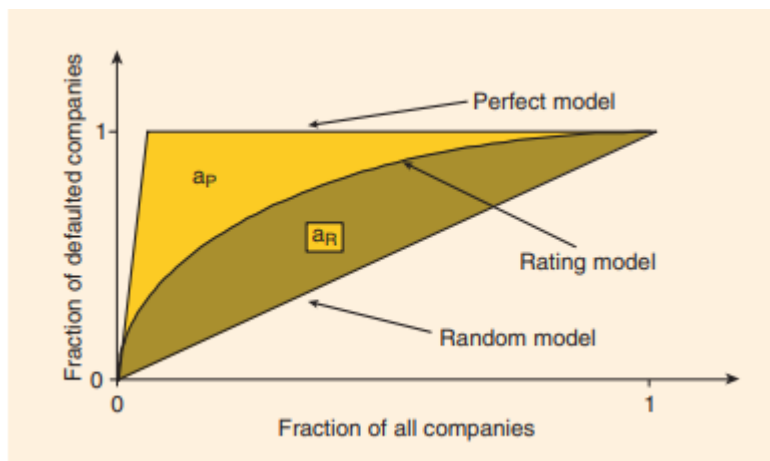
Obrázek 1: Křivka ROC

Zdroj: (Fawcett, 2006)

Křivka CAP (Cumulative Accuracy Profile) poskytuje informace o prediktivní síle modelů. Umožňuje zobrazit Error I (špatná firma klasifikovaná jako dobrá) a Error II (dobrá firma klasifikovaná jako špatná) pro všechny hodnoty skóre zároveň. Giniho koeficient, známý jako Accuracy ratio je definován jako poměr mezi plochou a_R , ta zahrnuje plochu mezi křivkou CAP ratingového a náhodného modelu, a plochou a_P , která zahrnuje plochu mezi křivkou CAP dokonalého a náhodného modelu. Čím blíže je ukazatel Accuracy ratio 1, tím lepší je metoda hodnocení. (Engelmann, Hayden a Tasche, 2003)

$$Accuracy\ ratio = GINI = \frac{a_R}{a_P} \quad (3)$$

Na následujícím obrázku je znázorněna křivka CAP, která zobrazuje křivky dokonalého, ratingového a náhodného modlu.



Obrázek 2: Křivka CAP

Zdroj: (Engelmann, Hayden a Tasche, 2003)

Vztah mezi Accuracy ratio a oblastí pod křivkou AUC je vyjádřen rovnicí:

$$Accuracy\ ratio = 2\ AUC - 1 \quad (4)$$

Kolmogorovův-Smirnovův test měří vzdálenost mezi empirickými kumulativními distribučními funkcemi vzorků dobrých a špatných případů:

$$KS = \left[\max \right]_s (F(s|B) - F(s|G)) \quad (5)$$

kde $F(\cdot|G)$ a $F(\cdot|B)$ označují empirické kumulativní distribuční funkce vzorků dobrých a špatných případů. (Ouenniche a kol., 2017)

2 CELOSVĚTOVÝ VÝVOJ V TVORBĚ BANKROTNÍCH MODELŮ OD ROKU 2015

V následující kapitole je uveden celosvětový vývoj v tvorbě bankrotních modelů. U modelů jsou uvedeni autoři, rok vytvoření, metoda, na které je model založen, odvětví a země původu podniků, vybraných pro testování. Dále vzorec a vysvětlení proměnných, mezní hodnota, určující bankrotní a bonitní podniky, míra úspěšnosti modelu a budoucí vývoj.

Bohužel ne všichni autoři zveřejnili všechna data, proto u některých modelů nejsou uvedeny všechny výše zmíněné údaje.

2.1 Vochozka, Straková a Váchal 2015

Model od Vochozky, Strakové a Váchala (2015) slouží k predikci přežití českých dopravních a lodních společností. Testovací soubor se skládal z dopravních podniků a byl tvořen absolutními a relativními ukazateli všech podniků zabývajících se dopravou v České republice v letech 2003–2012. Soubor dat byl z databáze Albertina a obsahoval 12 930 vstupních řádků. Výsledný model logistické regrese pro predikci přežití dopravních a lodních společností je v následující tabulce.

Tabulka 2: Predikční bankrotní model Vochozka, Straková a Váchal

Ukazatel	Parametr
konstanta	0.095064582
vlastní kapitál (v tis. Kč)	– 0.061965429
základní kapitál (v tis. Kč)	– 0.44632997
krátkodobé závazky	– 1.062014871
zisk/ztráta z běžné činnosti	– 0.002490906
pohledávky / oběžná aktiva (v %)	– 0.536248625
doba splatnosti závazků z obchodů ve dnech	– 0.25903599
pohotová likvidita	– 0.095270924
index pracovního kapitálu (v %)	+ 0.194857318
kapitálový koeficient přidané hodnoty (v %)	+ 0.205345429
dlouhodobé závazky / celkové závazky (v %)	– 0.149379695
krátkodobé závazky / celkové závazky (v %)	– 0.213213898
dlouhodobé úvěry a půjčky / celkové závazky (v %)	– 0.191000612

Zdroj: upraveno podle (Vochozka, Straková a Váchal, 2015)

Na základě analýzy citlivosti byla stanovena mezní hodnota 0,523748. Dopravní společnosti s hodnotou modelu 0,523748 a vyšší pravděpodobně přežijí potenciální finanční tíseň. V opačném případě mohou mít společnosti finanční problémy. Účinnost modelu je 91,75 %. Výzvou do budoucna je vyvinutí podobných modelů pro jednotlivé země v Evropě a ve světě, které berou v úvahu národní, regionální a místní podmínky. Složitější výzvou by bylo navržení celosvětově použitelného modelu, který by překonal specifické geografické rysy dopravních a lodních společností. (Vochozka, Straková a Váchal, 2015)

2.2 Shirinkina a Valiullina 2015

Autoři Shirinkina a Valiullina (2015) uvádějí, že zahraniční metody nemohou být plně vhodné pro hodnocení rizika bankrotu ruských podniků, z důvodu rozdílu inflačních faktorů, odlišné kapitálové struktury a rozdílů v legislativě. Data jsou od 27 ruských podniků různých průmyslových odvětví za období 2005–2015. Model je založen na vícenásobné regresi.

$$PH = -1,189 + 4,45x_1 + 0,28x_2 - 2,51x_3 + 0,0329x_4 + 0,19x_5 + 6,67x_6 \quad (6)$$

kde:

x_1 = čistý zisk / aktiva

x_2 = tržby z prodeje / aktiva

x_3 = čistý zisk / vlastní kapitál

x_4 = oběžná aktiva / celková aktiva

x_5 = oběžná aktiva / krátkodobé závazky

x_6 = zisk z prodeje / příjmy

Pokud se hodnota PH dostane do záporných hodnot, podniku hrozí bankrot. Při kladných hodnotách nehrozí riziko. (Shirinkina a Valiullina, 2015)

2.3 Ježovita 2015

Autorka Ježovita (2015) použila k sestavení bankrotního modelu vícerozměrnou diskriminační analýzu a logistickou regresi. Data jsou od 417 chorvatských společností za rok 2011. Firmy jsou z oblastí průmyslu, stavebnictví, obchodu a nefinančních služeb. Model diskriminační analýzy má následující tvar:

$$Z = 5,41 - 4,93 EUP - 0,08 FZ - 0,80 PTK - 0,89 ROE - 0,36 KT \quad (7)$$

kde:

$EUP = \text{celkové výnosy} / \text{celkové náklady}$

$FZ = \text{celkové závazky} / (\text{nerozdělený zisk} + \text{odpisy a amortizace})$

$PTK = (\text{hrubý zisk} + \text{finanční náklady}) / \text{finanční náklady}$

$ROE = \text{čistý zisk} / \text{vlastní kapitál}$

$KT = \text{oběžná aktiva} / \text{krátkodobé závazky}$

Při hodnotě diskriminační funkce nižší než 0,190447 je společnost považována za stabilní. Hodnota vyšší jak 0,190447 značí nestabilní společnost. Pokud hodnota funkce je nižší než - 1,30342 lze obchodní operace charakterizovat jako velmi stabilní. Hodnota vyšší jak 1,82096 charakterizuje velmi nestabilní kvalitu obchodních operací. Přesnost klasifikace modelu je 95,91 %. Model logistické regrese, který autorka Ježovita (2015) navrhla, má klasifikační schopnost 98,54 %.

2.4 Němec, Pavlík 2016

Němec a Pavlík (2016) vytvořili bankrotní model. Přístup je založen na standardní metodice logit modelování. Byly použity data z obchodního rejstříku českých společností za období 2005–2013. Vzorek se skládal z 175 556 společností ze všech odvětví. Model logit vyžaduje závislé proměnné jako fiktivní proměnnou. Jsou zde požadovány společnosti v úpadku (tj. ty které v daném roce zkrachovaly nebo zanikly).

Tabulka 3: Predikční bankrotní model Němec a Pavlík

Finanční ukazatele	Parametr
konstanta	0.0068
krátkodobá aktiva / krátkodobé závazky	-0.5160
aktiva / vlastní kapitál	-0.0559
závazky (externí zdroje) / aktiva	0.6346
CF (EBITDA) / závazky (externí zdroje)	-2.8307
vlastní kapitál / závazky (externí zdroje)	-1.1347
finanční aktiva*365 / prodej	-0.0016

Zdroj: upraveno podle (Němec a Pavlík, 2016)

Model predikuje na jeden rok dopředu a jeho predikční schopnost je 84 %. (Němec a Pavlík, 2016)

2.5 Šlefendorfas 2016

Šlefendorfas (2016) použil k vytvoření predikčního modelu v Litvě metodu vícenásobné diskriminační analýzy. Model je založen na datech malých a středních společností v Litvě s právní formou soukromé společnosti s ručením omezeným. Data jsou od 145 společností za období 2007–2013, které fungovaly alespoň 5 let. Model má následující tvar:

$$\begin{aligned}
 Z_{GS} = & 1,739 + 1,45 * \frac{\text{Tržby z prodeje}_t - \text{Tržby z prodeje}_{t-1}}{\text{Tržby z prodeje}_{t-1}} \\
 & + 0,922 * \frac{\text{Provozní náklady}_{t-3} - \text{Provozní náklady}_{t-4}}{\text{Provozní náklady}_{t-4}} + 1,307 \\
 & * \frac{\text{Provozní zisk}_t}{\text{Tržby z prodeje}_t} - 1,491 * \frac{\text{Celkové závazky}_{t-4}}{\text{Celková aktiva}_{t-4}} - 0,677 * \frac{\text{Čistý zisk}_{t-5}}{\text{Celkový kapitál}_{t-5}} \\
 & + 1,257 * \frac{\frac{\text{Celková aktiva}_t}{\text{Celkové závazky}_t} - \frac{\text{Celková aktiva}_{t-4}}{\text{Celkové závazky}_{t-4}}}{\frac{\text{Celková aktiva}_{t-4}}{\text{Celkové závazky}_{t-4}}} \\
 & + 0,1 * \frac{\frac{\text{Celkový kapitál}_t}{\text{Celkové závazky}_t} - \frac{\text{Celková kapitál}_{t-2}}{\text{Celkové závazky}_{t-2}}}{\frac{\text{Celková kapitál}_{t-2}}{\text{Celkové závazky}_{t-2}}} - 0,334 \\
 & * \frac{\frac{\text{Finanční a investiční náklady}_{t-2}}{\text{Tržby z prodeje}_{t-2}} - \frac{\text{Finanční a investiční náklady}_{t-4}}{\text{Tržby z prodeje}_{t-4}}}{\frac{\text{Finanční a investiční náklady}_{t-4}}{\text{Tržby z prodeje}_{t-4}}} - 0,246 \\
 & * \frac{\frac{\text{Provozní náklady}_{t-2}}{\text{Tržby z prodeje}_{t-2}} - \frac{\text{Provozní náklady}_{t-5}}{\text{Tržby z prodeje}_{t-5}}}{\frac{\text{Provozní náklady}_{t-5}}{\text{Tržby z prodeje}_{t-5}}}
 \end{aligned} \tag{8}$$

kde:

Z_{GS} = koeficient predikce bankrotu pro období t+1

t = aktuální rok

t – 1,2,3,4,5 = aktuální rok minus daný rok

Pokud jsou hodnoty Z_{GS} vyšší než 1,098 společnost bude fungovat. Při hodnotách od 1,098 do – 1,083 se nachází šedá zóna a nelze spolehlivě předpovědět. U hodnot nižších než – 1,083 může být společnost v bankrotu. Správnost klasifikace modelu je 89 %. (Šlefendorfas, 2016)

2.6 Durica a Adamko 2016

Autoři Durica a Adamko (2016) vytvořili predikční model pomocí vícenásobné diskriminační analýzy pro slovenské společnosti. Model byl vytvořen postupnou metodou na základě hodnot 11 poměrových ukazatelů. Data jsou od 109 550 slovenských společností. Model diskriminační funkce má následující tvar:

Tabulka 4: Predikční bankrotní model Durica a Adamko

Poměrový ukazatel	Parametr
Krátkodobá aktiva / krátkodobé závazky	0,25
EBIT / celková aktiva	0,51
Krátkodobé závazky / tržby	-0,207
Pracovní kapitál / celková aktiva	0,282
Vlastní kapitál / celkové závazky	0,618

Zdroj: upraveno podle (Durica a Adamko, 2016)

Společnost je zařazena do skupiny nezbankrotovaných při hodnotě diskriminační funkce vyšší než 0,020. Hodnoty od 0,020 do -0,061 značí šedou zónu. U hodnoty nižší než - 0,061 společnost může mít problémy s bankrotem. Model správně zařazuje 82,2 % společností. Mezi 5 proměnnými v predikčním modelu jsou 3 proměnné, které patří k nejčastěji používaným proměnným ve 24 predikčních modelech vícenásobné diskriminační analýzy v jiných zemích. (Durica a Adamko, 2016)

2.7 Almamy, Aston a Ngwa 2016

Autoři Almamy, Aston a Ngwa (2016) rozšířili Altmanův model Z-skóre pro předpovídání finančního zdraví britských společností. Zahrnuli data 1 000 úspěšných britských společností z roku 2013 a 90 neúspěšných společností, které zbankrotovaly během období 2000–2013. Model vícenásobné diskriminační analýzy se nazývá J-UK a má následující tvar:

$$Z_j = 1,484 J_1 + 0,043 J_2 + 0,390 J_3 + 0,424 J_5 + 0,75 J_6 \quad (9)$$

kde:

J1 = pracovní kapitál / celková aktiva

J2 = nerozdělený zisk / celková aktiva

J3 = zisk před úroky a zdaněním / celková aktiva

J4 = účetní hodnota vlastního kapitálu / celkové závazky

J5 = tržby / celková aktiva

J6 = provozní cash flow / celkové závazky

Klasifikační schopnost modelu je 89,2 %. Autoři Almamy, Aston a Ngwa (2016) porovnávali svůj model J-UK s Altmanovým Z-skóre (1968). Model J-UK byl v průměru přesnější o 11,37 % při porovnávání britských společností před, během a po finanční krizi.

2.8 Mihalovič 2016

Mihalovič (2016) sestavil model diskriminační analýzy a model logistické regrese pro Slovenskou republiku. Data byla od 236 zdravých a selhávajících společností na Slovensku z roku 2014. Model kanonické diskriminační funkce má podobu:

$$D(f) = -0,507 x_1 - 0,263 x_2 + 0,271 x_3 + 0,235 x_4 + 0,526 x_5 \quad (10)$$

Model logistické regrese má následující tvar:

$$\hat{p}(x) = \frac{e^{-(1,01044-0,73287 x_1-0,08631 x_2+1,05539 x_3-2,09519 x_4+0,54097 x_5)}}{1 + e^{-(1,01044-0,73287 x_1-0,08631 x_2+1,05539 x_3-2,09519 x_4+0,54097 x_5)}} \quad (11)$$

kde:

x_1 = čistý příjem / celková aktiva

x_2 = oběžná aktiva / krátkodobé závazky

x_3 = krátkodobé závazky / celková aktiva

x_4 = pracovní kapitál / celková aktiva

x_5 = oběžná aktiva / celková aktiva

U modelu diskriminační analýzy hodnoty větší než 0, znamenají finančně zdravou firmu. Hodnoty menší než 0 značí finančně nezdravou firmu. Model logistické regrese v této podobě není platný, protože celkový význam odchylek není dostatečný (p-hodnota je 0,0851). Model diskriminační analýzy správně klasifikuje na 64,41 % a model logistické regrese má klasifikační schopnost 68,64 %. (Mihalovič, 2016)

Autor Mihalovič (2016) udává, že modely v navrhované verzi nejsou aplikovány ve slovenském podnikatelském prostředí. Důvodem může být vybrání nevhodných proměnných. Cílem budoucího výzkumu je zajištění celkové výkonnosti modelu nebo vyvinutí nových modelových přístupů.

2.9 Alaminos a kol. 2016

Autoři Alaminos a kol. (2016) vytvořili pomocí logistické regrese prediktivní modely bankrotu pro Asii, Evropu a Ameriku. Jejich cílem bylo vytvořit globální model pro celý svět na období až tří let před bankrotem. Data byla od 440 nefinančních kótovaných společností ze tří regionů, Asie (Japonsko, Jižní Korea, Singapur a Tchaj-wan), Evropy (Rakousko, Dánsko, Francie, Německo, Irsko, Itálie, Lucembursko, Holandsko, Norsko, Portugalsko, Španělsko, Švédsko, Švýcarsko a Spojené království) a Ameriky (Bermudy, Kanada a Spojené státy americké). Údaje jsou ze období 1990–2013.

Model pro Evropu t–1:

$$Y(E)t - 1 = 1.899 + 10.532V1 - 1.812V2 - 25.680V5 + 8.059V8 + 5.626V9 \quad (12)$$

Model pro Evropu t–2:

$$Y(E)t - 2 = 1.046 - 1.959V2 + 9.923V3 + 1.722V4 - 20.098V5 + 4.360V8 \quad (13)$$

Model pro Evropu t–3:

$$Y(E)t - 3 = -1.465 + 1.852V3 + 2.166V4 - 16.299V5 + 0.803V6 + 3.468V8 \quad (14)$$

Globální model s regionální proměnnou t–1:

$$Y(Gd)t - 1 = -2.695 + 6.635V3 - 18.292V5 + 4.759V9 + 0.713Region \quad (15)$$

Globální model s regionální proměnnou t–2:

$$Y(Gd)t - 2 = -2.343 - 0.767V2 - 11.426V5 + 3.624V8 + 3.385V9 + 0.502Region \quad (16)$$

Globální model s regionální proměnnou t–3:

$$Y(Gd)t - 3 = -2.867 - 2.728V3 - 9.992V5 + 2.833V8 + 3.633V9 + 0.446Region \quad (17)$$

kde:

V1 = zisk / celková aktiva

V2 = oběžná aktiva / krátkodobé závazky

V3 = pracovní kapitál / celková aktiva

V4 = nerozdělený zisk / celková aktiva

V5 = EBIT / celková aktiva

V6 = Tržby / celková aktiva

V8 = oběžná aktiva / celková aktiva

V9 = oběžná aktiva / celková aktiva

Region - 1 pro Asii, 2 pro Evropu a 3 pro Ameriku

t = aktuální rok

Při hodnotě 1 může být společnost v úpadku. U neúpadkové společnosti je hodnota 0. Všechny modely mají přesnost nad 80 %. Nejvyšší klasifikační schopnost má globální model s použitím regionálních proměnných. Ve výzkumu autoři Alaminos a kol. (2016) prokázali, že predikce mezinárodního bankrotu není ovlivněna odvětvím, do kterého společnost patří. Budoucí výzkum by mohl zkoumat, které makroekonomické podmínky ovlivňují chování finančních proměnných. Pro zvýšení zobecnění výsledků by měly být zahrnuty údaje i od malých a středních podniků.

2.10 Herman 2017

Herman (2017) vytvořil modely pomocí metody bootstrapping a multivariační diskriminační analýzy. Data byla od 180 akciových společností obchodovatelných na polském kapitálovém trhu z odvětví stavebnictví, výroby a obchodu za období 2000–2013. Autor konstruoval modely samostatně pro každé odvětví. Model pro stavebnictví je následující:

$$D = -0,30 \cdot WBP + 0,29 \cdot MZO + 0,66 \cdot KP + 0,46 \cdot KWZ + 0,23 \cdot KW \quad (18)$$

Druhý model bankrotu akciových společností pro zpracovatelský průmysl:

$$D = 0,22 \cdot ZB + 0,49 \cdot ZS - 0,19 \cdot ZO + 0,15 \cdot MZO + 0,46 \cdot KWZ \quad (19)$$

Poslední model je zkonstruován z firem velkoobchodu a maloobchodu:

$$D = 0,26 \cdot ROA + 0,38 \cdot MZ2 + 0,31 \cdot WBP - 0,08 \cdot WSP + 0,51 \cdot KWZ \quad (20)$$

Vysvětlení proměnných (Herman, 2017):

WBP = oběžná aktiva / krátkodobé závazky

MZO = provozní zisk / čisté tržby

KWZ = vlastní kapitál / dluh

KW = vlastní kapitál / aktiva

ZB = hrubý zisk / čisté tržby

ZS = (náklady na prodané zboží – čisté tržby) / čisté tržby

ZO = celkový dluh / aktiva

ROA = EBIT / celková aktiva

MZ2 = (výnosy – náklady) / výnosy

WSP = (oběžná aktiva – zásoby) / krátkodobé závazky

Jediný společný znak všech modelů je poměr dluhu vůči vlastnímu kapitálu. Kladné hodnoty kvalifikují firmu jako zdravou. Záporné hodnoty naznačují, že společnost má špatnou finanční situaci a je ohrožena bankrotem. Schopnost klasifikace modelu stavebnictví je 78,14 %, u modelu výroby je 89,55 % a pro model obchodu vychází na 72,33 %. (Herman, 2017)

2.11 Altman a kol. 2017

Altman a kol. (2017) znovu odhadli Altmanovo Z'' skóre z roku 1983. Autoři použili k odhadu modelů vícenásobnou diskriminační analýzu a logistickou regresní analýzu. Data zahrnovala údaje od středních a větších firem z různých odvětví za období 2007–2010. Společnosti byly z 31 evropských zemí a 3 zemích mimo Evropu (USA, Číny a Kolumbie).

Model vícenásobné diskriminační analýzy má tvar:

$$\text{Model MDA} = -0,042 - 0,561 X1 - 0,724 X2 - 1,791 X3 - 0,021 X4 \quad (21)$$

Model logistické regrese má tvar:

$$\text{Model LR} = \frac{1}{1 + e^{-(0,035 - 0,495 X1 - 0,862 X2 - 1,721 X3 - 0,017 X4)}} \quad (22)$$

kde:

X1 = pracovní kapitál / celková aktiva

X2 = nerozdělený zisk / celková aktiva

X3 = EBIT / celková aktiva

X4 = účetní hodnota vlastního kapitálu / celkové závazky

U vícenásobné diskriminační analýzy mezní hodnotou, která odděluje finančně zdravé a nezdravé, je 0. U logistické regrese je mezní hodnota 0,5. Modely mají podobnou predikční schopnost (hodnota AUC je 0,745 u vícenásobné diskriminační analýzy a 0,748 u logistické regrese). Další modely logistické regrese zahrnují proměnné velikosti, stáří firem, roku bankrotu, odvětví a hodnocení rizika zemí. Přidání proměnných zvyšuje predikční schopnost modelů, ale výsledky u jednotlivých zemí se liší. Další výzkum by se mohl zaměřit na zavádění nových proměnných (např. makroekonomická dat), testování s daty z rozvíjejících se trhů. (Altman a kol., 2017)

2.12 Adamko, Klieštk a Kováčová, 2018

Autoři Adamko, Klieštk a Kováčová (2018) vytvořili obecný model založený na logistické regresi. Slouží k předpovědi bankrotu slovenských společností na jeden rok dopředu. Data byla čerpána z databáze Amadeus od společností z různých odvětví za roky 2014–2016. K vytvoření modelu byla použita data z roku 2014 a 2015 k vypočítání prediktorů a proměnných.

Podmínky pro identifikování podniku v krizi:

- poměr vlastního kapitálu a pasiv je menší než 0,4,
- rychlý test je menší než 1,
- zisk po zdanění je menší než 0,
- celková aktiva jsou menší než dlouhodobé a krátkodobé závazky.

Model podle autorů Adamko, Klieštk a Kováčová (2018):

$$t = -1,1494 + 0,0027 * X1 - 0,0036 * X2 + 0,0034 * X3 - 0,0061 * X4 \quad (23)$$

Vysvětlení proměnných:

$X1$ = pracovní kapitál / celková aktiva

$X2$ = provozní EBIT / celková aktiva

$X3$ = (dlouhodobé + krátkodobé závazky) / celková aktiva

$X4$ = (čistý příjem + odpisy) / (krátkodobé + dlouhodobé závazky)

Vypočtená hodnota t se dosadí do následujícího vzorce:

$$c = \frac{1}{1 + e^{-t}} \quad (24)$$

Pokud je hodnota c větší než mezní hodnota 0,241, společnost se v příštím roce může ocitnout v krizi. (Adamko, Klieštk a Kováčová, 2018)

2.13 Svabova, Durica a Podhorska 2018

Svabova, Durica a Podhorska (2018) k vývoji predikčního modelu pro slovenské malé firmy použili metodu lineární diskriminační analýzy. Data byla od 88 252 malých slovenských podniků z roku 2015, které predikovaly možnou existenci finančních potíží v roce 2016. Za malou společnost byla považována společnost do 50 zaměstnanců. Model lineární diskriminační analýzy má následující tvar:

$$\begin{aligned} Z - score = & -0,263 * X04 - 5,823 * X07 + 3,022 * X10 - 0,707 * X21 \\ & + 0,019 * X25 + 4,707 * X27 - 0,069 * X28 - 1,592 \end{aligned}$$

(25)

kde:

$X04 = \text{čistý příjem} / \text{vlastní kapitál akcionářů}$

$X07 = \text{čistý příjem} / \text{celková aktiva}$

$X10 = (\text{dlouhodobé} + \text{krátkodobé závazky}) / \text{celková aktiva}$

$X21 = \text{dlouhodobé závazky} / \text{celková aktiva}$

$X25 = \text{oběžná aktiva} / \text{krátkodobé závazky}$

$X27 = \text{EBIT} / \text{celková aktiva}$

$X28 = \text{EAT} / \text{vlastní kapitál}$

Pro zjištění, zda je společnost prosperující nebo neprospěující, se porovnává její Z-skóre s nulou. Pokud je Z-skóre záporné, firma je prosperující, a když je Z-skóre kladné, společnost je ve skupině neprospěujících. Model správně zařadil 93,1 % neprospěujících společností v rámci testovacího vzorku a 93 % neprospěujících společností v tréninkovém vzorku. Do budoucna je možnost ověřit validitu modelu nebo zlepšit jeho predikční schopnost aplikací na aktuálnějších datech malých firem od roku 2017. (Svabova, Durica a Podhorska, 2018)

2.14 Klieštk, Vrbka a Rowland 2018

Pro země Visegrádské čtyřky autoři Klieštk, Vrbka a Rowland (2018) vytvořili bankrotní modely za použití vícenásobné diskriminační analýzy. Vytvořili jednotlivé modely pro každou zemi a jeden komplexní model pro celou skupinu. Data byla z databáze Amadeus za

období 2015–2016 pro zemědělství, těžbu, výrobu, dodávku elektřiny, konstrukci, velkoobchod a maloobchod, přepravu a skladování, ubytování a stravování, informace a komunikace, administrativní činnosti, vzdělání, lidské zdraví a sociální pracovní aktivity (kategorie A–Q v klasifikaci NACE). Finanční údaje 449 781 malých, středních a velkých podniků byly ze Slovenské republiky, České republiky, Polska, Maďarska, Rumunska, Bulharska, Litvy, Lotyšska, Estonska, Slovinska, Chorvatska, Srbska, Ruska, Ukrajiny, Běloruska, Černé Hory a Makedonie.

Predikční model pro Slovensko:

$$y_{SK} = -1,565 + 0,025 X_2 - 0,408 X_4 - 7,663 X_7 + 2,268 X_{10} - 0,419 X_{11} + 0,35 X_{12} + 0,926 X_{15} + 6,082 X_{27} + 0,107 X_{28} \quad (26)$$

Predikční model pro Českou republiku:

$$y_{CZ} = -1,016 + 0,007 X_2 - 0,884 X_4 + 2,168 X_7 - 0,343 X_8 + 2,526 X_{10} + 0,416 X_{12} - 0,592 X_{21} - 2,561 X_{27} + 0,352 X_{28} - 1,075 X_{35} \quad (27)$$

Predikční model pro Polsko:

$$y_{PL} = -1,563 + 0,075 X_2 - 1,388 X_4 + 0,658 X_7 + 3,001 X_{10} - 0,676 X_{11} + 1,067 X_{12} + 1,043 X_{15} - 0,048 X_{26} + 0,458 X_{28} - 1,213 X_{35} \quad (28)$$

Predikční model pro Maďarsko:

$$y_H = -1,516 + 0,057 X_2 - 1,380 X_9 + 3,967 X_{10} - 0,681 X_{11} + 1,561 X_{12} - 1,607 X_{21} - 0,05 X_{22} - 0,647 X_{28} \quad (29)$$

Komplexní predikční model pro země Visegrádské čtyřky:

$$y_{V4} = -1,470 + 0,024 X_2 - 0,589 X_4 - 1,158 X_7 + 1,870 X_{10} - 0,452 X_{11} + 0,613 X_{12} + 1,030 X_{15} - 0,012 X_{22} + 0,731 X_{27} + 0,173 X_{28} - 0,475 X_{35} + 0,244 CZ + 0,522 SK \quad (30)$$

kde:

X_2 = oběžná aktiva / krátkodobé závazky

X_4 = čistý zisk / vlastní kapitál

$X_7 = \text{čistý zisk} / \text{celková aktiva}$

$X_8 = \text{pracovní kapitál} / \text{celková aktiva}$

$X_9 = \text{provozní zisk} / \text{celková aktiva}$

$X_{10} = (\text{dlouhodobé} + \text{krátkodobé závazky}) / \text{celková aktiva}$

$X_{11} = \text{oběžná aktiva} / \text{celková aktiva}$

$X_{12} = \text{hotovost a peněžní ekvivalenty} / \text{celková aktiva}$

$X_{15} = \text{krátkodobé závazky} / \text{celková aktiva}$

$X_{21} = \text{dlouhodobé závazky} / \text{aktiva celkem}$

$X_{22} = \text{hotovost a peněžní ekvivalenty} / \text{krátkodobé závazky}$

$X_{26} = (\text{oběžná aktiva} - \text{zásoby}) / \text{krátkodobé závazky}$

$X_{27} = \text{EBIT} / \text{celková aktiva}$

$X_{28} = \text{EAT} / \text{vlastní kapitál}$

$X_{35} = \text{EAT} / \text{tržby}$

fiktivní proměnné CZ, SK – při výpočtu slovenských a českých podniků u modelu V4 se používá 1, jinak 0

Výsledek diskriminační funkce se porovnává s 0. Kladná hodnota určuje neprosperující podnik. Záporná hodnota značí prosperující podnik. Nejlepší predikční schopnost má polský model s 88,4 %. Druhý je komplexní model Visegrádské čtyřky s predikční schopností 85,7 %, třetí model pro Českou republiku predikuje s 84,8 %. Čtvrtý v pořadí je slovenský model s predikční schopností 82,7 % a nejhorsí predikční schopnost s 81,6 % má maďarský model. (Kliestik, Vrbka a Rowland, 2018)

2.15 Jenčová, Štefko a Vašaničová 2020

Bodový model finanční výkonnosti od autorů Jenčová, Štefko a Vašaničová (2020) je založen na logistické regresi. Model je vytvořen pro slovenské firmy v elektrotechnickém průmyslu, lze ho použít i pro slovenské firmy ve strojírenství. Autoři použili data od 1 000 největších nefinančních podniků slovenského elektrotechnického průmyslu za rok 2017. Model logistické regrese má následující tvar:

$$\ln \frac{p}{1-p} = -1498 + 0,0218 * APTR - 1987 * ROS - 10,192 * QR + 0,074 * FL - 0,370 * \frac{NWC}{A}$$

(31)

kde:

APTR – doba obratu závazků (tj. doba, během které společnost platí své závazky)

ROS – rentabilita tržeb = zisk před úroky, daněmi, odpisy a amortizací (EBITDA) / tržby

QR – pohotová likvidita = (oběžná aktiva – zásoby) / krátkodobé závazky

FL – finanční páka = aktiva / vlastní kapitál

NWC/A – čistý pracovní kapitál / aktiva

Celková úspěšnost modelu v elektrotechnickém průmyslu byla 84 %. Hlavním omezením bylo analyzování pouze roku 2017. Předpoklad pro budoucí výzkum je odhad modelu pro delší časové řady, dále přidání v úvahu dalších proměnných (např. proměnné týkající se regionu a velikosti podnikatelského subjektu). (Jenčová, Štefko a Vašaničová, 2020)

2.16 Ogachi a kol. 2020

Model logistické regrese vytvořili autor Ogachi a kol. (2020) v Keni. Model lze použít k predikci finančně ohrožených společností na nairobijském trhu cenných papírů a burzy. Data obsahovala 64 kótovaných společností v Keni a byla použita jejich desetiletá účetní závěrka. Model logistické regrese má tvar:

$$P = \frac{1}{1 + e^{-(-0.068X1 + 2.269X2 - 4.987X3 - 0.075X4 + 2.853X5 - 3.296X6 - 0.059X7 + 0.086X8)}}$$

(32)

kde:

X1 = náklady na prodané zboží / zásoby

X2 = tržby / celková aktiva

X3 = dluh / vlastní kapitál

X4 = čistý úvěrový prodej / průměrná účetní pohledávka

X5 = celková aktiva

X6 = celková pasiva / vlastní kapitál

$X7 = \text{krátkodobá aktiva} / \text{krátkodobé závazky}$

$X8 = \text{krátkodobá aktiva} / \text{krátkodobé závazky}$

Hodnoty s číslem 0,5 a vyšším znamenají, že se společnost nachází ve finanční tísní. U čísla pod 0,5 společnost ve finanční tísní není. Hodnota 0 značí indiferentní stav firmy. Logistický model správně klasifikoval 83 % případů. (Ogachi a kol., 2020)

2.17 Voda, Dobrotě a kol. 2021

Autoři Voda a kol. (2021) vytvořili v roce 2021 model, který je zaměřený na hodnocení rizika bankrotu v rumunském podnikatelském prostředí. Cílem bylo prodloužit předvídatelnost na tři roky při zachování vysokého stupně přesnosti. Data společností byla z kapitálového rumunského trhu z výrobního a těžebního průmyslu. Ve výzkumu bylo 80 společností, z nichž 50 % je v insolvenčním řízení. Data byla shromážděna za období 2015-2018. Vybrané společnosti jsou v kategorii střední a velké podniky, podle kritérií celkových aktiv a obrátu. Identifikace sady relevantních proměnných byla provedena aplikací analýzy postupných odhadů nejmenších čtverců metodou Forwards. Autoři vytvořili model lineární regrese R pro odhad rizika bankrotu, který má následující formu:

$$R = -4.019 + 0.066xr_1 - 0.060xr_2 + 0.844xr_3 + 5.182xr_4 - 0.952xr_5 \quad (33)$$

Vysvětlení použitých indikátorů:

xr_1 (poměr dluhu k aktivům) = celkový dluh / celková aktiva

xr_2 (poměr globální solventnosti) = (čistý příjem + odpisy) / (krátkodobé + dlouhodobé závazky)

xr_3 (poměr krátkodobého dluhu) = oběžná aktiva / krátkodobé závazky

xr_4 (poměr globální finanční autonomie) = vlastní kapitál / celková pasiva

xr_5 (návrátlost aktiv) = EBIT / celková aktiva

Finančně stabilní podniky jsou v intervalu spolehlivosti, když hodnota R je nižší než $-0,466$. Střední riziko bankrotu a interval nejistoty je při hodnotě R od $-0,466$ do $0,467$. A společnosti úpadkové mají interval rizika při hodnotě R větší než $0,467$. Přesnost modelu pro předpovídání rizika bankrotu nebo platební neschopnosti rok předem je s přesností 96,25 %. Průměrná míra chyb u tohoto modelu aplikovaná jeden rok před bankrotem je 7,5 %. Prognózu dva roky před bankrotem lze předpovědět na 88,75 %. Při použití modelu lze riziko

bankrotu identifikovat o tři roky dříve v poměru o 77,5 % v případě společností s nepříznivou finanční situací. (Voda a kol., 2021)

Autoři Voda a kol. (2021) nacházejí ve výzkumu určitá omezení, jako je dostupnost údajů, která neumožnila studii provést na úrovni většího vzorku. Budoucí výzkum vyžaduje také vztah k makroekonomickým podmínkám, daním, finančních politikách a dalším ekonomickým faktorům, které ovlivňují vývoj finančních proměnných používaných při predikci bankrotu. Nový směr výzkumu by mohl představovat vývoj modelu pro všechny kategorie společností (malé, střední a velké).

2.18 Adamowicz a Noga 2021

Autoři Adamowicz a Noga (2021) začali s vývojem modelu již v roce 2018 a dokončili ho v roce 2021. Model predikce bankrotu byl vyvinut speciálně pro dřevozpracující průmysl v Polsku. Podniky byly vybrány na základě polské klasifikace činností, kde převažovalo dřevo ve výrobním procesu. Ve výzkumu byly společnosti s ručením omezeným, akciové společnosti, veřejné obchodní společnosti a družstva. Základní metodou výzkumu byla vícenásobná diskriminační analýza. K vytvoření modelu byly použity účetní ukazatele. Ke konstrukci modelu byla použita finanční data od 135 podniků.

Koeficienty diskriminačních funkcí pro dřevozpracující průmysl byly odhadnuty na základě kanonické analýzy s použitím vyváženého vzorku. Model predikce bankrotu FMWE (Adamowicz a Noga, 2021):

$$FMWE = -0.5831 + 3.8767 x X1 + 0.0013 x X2 - 0.1012 x X3 - 0.0082x X4 + 0.0003 x X5$$

(34)

Vysvětlení proměnných (Adamowicz a Noga, 2018):

X1 = oběžná aktiva / krátkodobé závazky (Prusak)

X2 = celkové tržby / průměrná roční celková aktiva (Hołda)

X3 = vlastní kapitál / celkový dluh (Altman)

X4 = (zisk z provozní činnosti – odpisy) / tržby (Wierzba)

X5 = provozní náklady / krátkodobé závazky (Prusak)

Prahová hodnota, která rozděluje podniky na finančně zdravé a nezdravé, je 0. Obecná účinnost modelu Adamowicz a Noga (2021) na základě ročních údajů byla 89 %. S využitím

údajů ze dvou let před prognózou činila obecná účinnost 87 % a u tříletého období je účinnost 77 %.

Do budoucna je třeba stále hledat lépe upravené modely pro dřevozpracující průmysl, protože při výsledcích predikce založených na tří letých datech byl model Poznań (Pz), se kterým autoři porovnávali své výsledky, přesnější než model FMWE. Model Poznań dosáhl 83 %. (Adamowicz a Noga, 2021)

2.19 Horváthová, Mokrišová a Petruška 2021

Horváthová, Mokrišová a Petruška (2021) vytvořili model pro slovenské společnosti působící v teplárenském průmyslu. Jedná se o specifické odvětví, které hraje důležitou roli v každodenním životě společnosti a spotřebitelů. Dalším specifikem je, že teplo nelze obchodovat mezi zeměmi z důvodu značných tepelných ztrát při přenosu a distribuci a nelze s ním obchodovat mezi sítěmi existujícími v jednotlivých lokalitách. Autoři vytvořili dva modely pomocí neuronových sítí a diskriminační analýzy. Data byla od 444 teplárenských slovenských společností z roku 2016. Diskriminační funkce má následující podobu:

$$D = 0.553 + 0.083 ACP + 0.058 IT + 0.094 TATR + 0.217 ROA + 0.129 ROC + 0.119 EDR + 0.067 EFAR - 0.775 C \quad (35)$$

kde:

$ACP = \text{krátkodobé pohledávky} / \text{tržby} * 360$

$IT = \text{zásoby} / \text{tržby} * 360$

$TATR = \text{tržby} / \text{aktiva}$

$ROA = \text{EBIT} / \text{aktiva} * 100$

$ROC = \text{EAT} / \text{náklady} * 100$

$EDR = \text{vlastní kapitál} / \text{dluh}$

$EFAR = \text{vlastní kapitál} / \text{stálá aktiva}$

$C = \text{náklady} / \text{výnosy}$

Prosperující podniky dosahují hodnotu 0,203 a vyšší. Hodnoty od 0,203 do – 0,951 jsou v šedé zóně. Neprosperující podniky jsou od hodnoty – 0,951 a nižší. Predikční schopnost modelu je 84 %. (Horváthová, Mokrišová a Petruška, 2021)

Druhý model, kteří autoři Horváthová, Mokrišová a Petruška (2021) vytvořili pomocí umělých neuronových sítí, pracoval s 11 finančními ukazateli. Klasifikační schopnost modelu je 95,9 %. Model pomocí neuronových sítí je přesnější pro predikci bankrotu. Zadluženost je významný prediktor u vzorku podniků působících v tepelném hospodářství, protože dosahuje až 84 %.

2.20 Cindik a Armutlulu 2021

Autoři Cindik a Armutlulu (2021) analyzovali Altmanovi modely, upravili je pro podmínky Turecka za použití diskriminační analýzy, kvadratické diskriminační analýzy a strojového učení Random forest. Údaje byly z analýzy poměrových finančních ukazatelů 80 firem za roky 2013–2018 v Turecku. Firmy byly klasifikovány jako soukromé malé a mikropodniky a veřejné střední a velké podniky. Odvětví společností jsou chemie, konstrukce, informatika, nábytek, textil, jídlo, inženýrství a energie. Data společností tvoří 40 zdravých a 40 nezdravých podniků. Autoři revidovali Altmanův model Z'' z roku 1983 a upravili pro turecké podmínky. Model má následující tvar:

$$\text{Revidované Z Scóre} = - 0.519X_1 + 1.788X_2 + 3.874X_3 - 0.018X_4 \quad (36)$$

Použité proměnné jsou z modelu Z'' od Altmana (1983):

X_1 = pracovní kapitál / celková aktiva

X_2 = nerozdělený zisk / celková aktiva

X_3 = zisk před úroky a zdaněním / celková aktiva

X_4 = účetní hodnota vlastního kapitálu / celková pasiva

Pokud je hodnota vyšší než 2,60, jsou firmy klasifikovány jako nezkrachovalé. Zařazení do šedé zóny je při hodnotě od 1,10 až 2,60. Hodnota nižší než 1,10 značí vysoké riziko úpadku. (Altman, 1983) Přesnost klasifikace revidovaného modelu je 85 %. Při použití kvadratické diskriminační analýzy je přesnost 83,75 %. (Cindik a Armutlulu, 2021)

Poslední metodu, kterou Cindik a Armutlulu (2021) použili je Random forest. Do modelu použili stejné proměnné jako pro revidované Z scóre. Přesnost klasifikace je 95 %. Modely diskriminační analýzy a kvadratické diskriminační analýzy mají vyšší přesnost u soukromých malých a mikropodniků. Metoda Random forest má 100 % přesnost u veřejně obchodovaných středních a velkých podniků.

2.21 Sfakianakis 2021

Sfakianakis (2021) sestavil model pomocí multivariační diskriminační analýzy. Data byla od 28 výrobních kótovaných firem na burze v Řecku za období 2008–2015. Zvolené období je přesně v rámci Řecké finanční krize. Autor vytvořil tři modely na základě období blížího se bankrotu ($t-1$, $t-2$, $t-3$), vždy za použití stejného souboru vybraných proměnných. Proměnné jsou $X_1 = \text{EVA} / \text{celková aktiva}$, $X_2 = (\text{Oběžná aktiva} - \text{zásoby}) / \text{krátkodobé závazky}$ a $X_3 = (\text{provozní cash flow} + \text{úroky} + \text{daň}) / \text{úroky}$.

Model jeden rok před bankrotem ($t-1$):

$$Z = -2,369 + 0,238 X_1 + 3,474 X_2 + 0,033 X_3 \quad (37)$$

Pokud se hodnota blíží k $-1,336$ firma je klasifikována jako v úpadku, když se hodnota blíží k $1,336$ firma je klasifikována jako neúpadková. Hodnoty blízké nule znamenají indiferenci. Správnost klasifikace modelu je 96,43 %. (Sfakianakis, 2021)

Model dva roky před bankrotem ($t-2$):

$$Z = -0,084 + 3,833 X_1 + 0,565 X_2 + 0,079 X_3 \quad (38)$$

Při hodnotě blíží se k $-0,866$ je firma zařazena jako bankrotní. Nulové hodnoty značí indiferenci a hodnoty dosahující $0,866$, klasifikují neúpadkový podnik. Klasifikační schopnost modelu je 92,86 %. (Sfakianakis, 2021)

Model tři roky před bankrotem ($t-3$):

$$Z = -1,101 + 5,270 X_1 + 1,643 X_2 - 0,013 X_3 \quad (39)$$

U hodnoty blíží se k $-0,892$ je firma klasifikována jako bankrotní. Na druhé straně hodnoty blíží se k $0,892$ klasifikují firmu jako neúpadkovou. Hodnoty okolo nuly jsou indiferentní. Model správně klasifikuje na 89,29 %. Autor Sfakianakis (2021) se v budoucnu chce zaměřit na řecké nekótované malé a střední podniky, které také zkrachovaly.

2.22 Přehled ostatních modelů

Tato podkapitola se zaměřuje na bankrotní modely, které jsou vytvořené pomocí jiných metod, než je vícenásobná diskriminační analýza a logistická regrese.

Singh a Mishra 2016

Autoři Singh a Mishra (2016) zformulovali model predikce bankrotu pro indické výrobní společnosti. Vzorek zahrnoval 208 výrobních společností za období 2006–2014. Pro vytvoření modelu bylo použito 25 finančních ukazatelů a byla použita logit technika. Schopnost predikce modelu u testovacího vzorku je 98,46 % pro jeden rok před bankrotem a 86,92 % dva roky před bankrotem. U ověřovacího vzorku je to 89,74 % za jeden rok a 70,51 % za dva roky před selháním. Omezením modelu je, že ho lze aplikovat pouze na výrobní firmy a nezahrnuje finanční firmy.

Zhao a ostatní 2017

Autoři Zhao a ostatní (2017) uvádějí efektivní model predikce bankrotu založený na Kernel Extreme Learning Machine (KELM). Vstupní data se skládají z finančních poměrových ukazatelů společností v bankrotu a zdravých společností. Byl použit datový soubor Wieslaw, který obsahuje 30 finančních poměrových ukazatelů a 240 případů mezi roky 1997 a 2001 v Polsku. Průměrná klasifikační přesnost je 82,50 %.

Durica, Frnda a Svabova 2019

Autoři Durica, Frnda a Svabova (2019) vytvořili dva modely pomocí rozhodovacích stromů. Modely jsou pro polské ekonomické prostředí a predikují bankrot na jeden rok dopředu. Data jsou od 29 000 společností v Polsku za rok 2016–2017. První model založený na algoritmu CART (Klasifikační a regresní stromy) se třemi úrovněmi uzlů, čtyřmi neterminálními uzly a pěti terminálními uzly, za použití hodnot 23 finančních ukazatelů má přesnost 97,9 %. Druhý model založený na algoritmu CHAID (Automatická detekce interakce chí-kvadrát) s 57 uzly, využívá hodnot 12 finančních ukazatelů a jeho přesnost je 98,2 %.

Korol 2019

Korol (2019) vytvořil čtyři predikční metody – vícevrstvou neuronovou sítí, rekurentní neuronovou sítí, fuzzy množiny a rozhodovací stromy za použití 20 finančních ukazatelů. Autor použil údaje od 600 podniků všech velikostí, které na trhu působily alespoň 10 let od roku 2004 do roku 2017. Podniky z výrobního odvětví, služeb a maloobchodu byly z Německa, Francie, Spojeného království, Španělska, Finska, Itálie, Polska, Švédska a Dánska. Největší efektivita byla dosažena modelem s fuzzy množinami s 96,2 % správnou klasifikací rok před bankrotem. Druhým je model rekurentní neuronové sítě s účinností 95,2 % rok před bankrotem. Třetí je vícevrstvá neuronová sítí s účinností 93,4 % jeden rok před bankrotem. Nejmenší efektivitu mají rozhodovací stromy s účinností 93,0 % rok před

bankrotem. Dynamické modely (fuzzy množiny, vícevrstvé a rekurentní neuronové sítě) mají účinnost nad 80 % v horizontu prognózy do 6 lety před bankrotem.

Giriūniene a kol. 2019

Autoři Giriūniene a kol. (2019) sestavili model pro stavební sektor v Litvě založený na makroekonomických proměnných. Byly vybrány akciové společnosti s účetní závěrkou ověřenou auditorem, které během období analýzy neprošly restrukturalizací. Kritérium pro výběr společností úpadku bylo zahájení nebo skončení konkurzního řízení v průběhu let 2014–2017. Pro analýzu autoři vybrali 24 společností z Litvy splňující kritéria. Pro konečný model byly použity cenový poměr prvků stavebních nákladů, míra nezaměstnanosti a změna cen nemovitostí.

Pro zlepšení predikce autoři Giriūniene a kol. (2019) kombinovali model s již vytvořeným od autorů Butkus a kol. (2014), který obsahuje finanční poměrové ukazatele. Spolehlivost predikce kombinovaného modelu je 93,3 %.

Svabova a kol. 2020

Svabova a ostatní (2020) vytvořili predikční modely pro malé a střední firmy na Slovensku. Data jsou od 75 652 slovenských společností z databáze Amadeus za roky 2016–2018. Vytvořili tři predikční modely založené na kombinaci diskriminační analýzy a logistické regrese. První 1letý predikční model (data z roku 2016 a prosperita firmy z roku 2017) s predikční schopností 90,6 %. Druhý 1letý predikční model (data z roku 2017 a prosperita firmy z roku 2018) s predikční schopností 93,8 %. A třetí 2letý predikční model (data z roku 2017 a prosperita firmy z roku 2018) s predikční schopností 90,4 %.

Horák, Vrbka a Suler 2020

Horák, Vrbka a Suler (2020) vytvořili model pro průmyslové podniky působící v České republice. Data společností ze sekce C – výroba z CZ-NACE byla za roky 2013–2017. Autoři vytvořili model za použití Support vector machine s přesností predikce bankrotu 76,08 % a 5 modelů umělých neuronových sítí. Modely umělých neuronových sítí vykazují vyšší predikční schopnost až 83 %.

Brédart, Séverin a Veganzones 2020

Brédart, Séverin a Veganzones (2020) zahrnuli do modelu kombinaci finančních proměnných a proměnné z lidských zdrojů. Data byla od 1 000 nekótovaných společností s minimálně 20 zaměstnanci za roky 2015–2017 z Belgie. Vybrané proměnné z lidských zdrojů jsou podíl počtu hodin školení a průměrného počtu pracovníků za rok. Druhou

proměnnou je podíl pracovních smluv na dobu neurčitou za rok. Autoři vytvořili 4 modely za použití logistické regrese, Support vector machine, umělé sítě, rozhodovacích stromů a extreme learning machine. Model jen s finančními ukazateli dosáhl přesnosti okolo 80 %. Přidání proměnných z lidských zdrojů zvýšilo přesnost modelu až na 84,6 %.

Vochozka, Vrbka a Suler 2020

Autoři Vochozka, Vrbka a Suler (2020) vyvinuli model, který byl vytvořen pomocí umělé neuronové sítě pro hluboké učení s použitím minimálně jedné vrstvy dlouhodobé krátkodobé paměti (LSTM). K řešení byl použit software Wolfram's Mathematica. Soubor zahrnoval data 5500 společností z České republiky z roku 2014-2018. Model je schopen predikovat budoucí vývoj společností působící ve výrobním sektoru v České republice.

Abid a kol. 2021

Abid a kol. (2021) vytvořili dva modely predikce bankrotu založené na metodách výběru proměnných pomocí neuronových sítí, a jsou to HVS-AUC a forward-AUC postup. Data tvořila 856 francouzských společností z průmyslového sektoru z roku 2006. Predikční schopnost modelů je 84,5 %.

Pavlicko, Durica a Mazanec, 2021

Model od Pavlicka, Durici a Mazance (2021) slouží jako predikční model na jeden rok dopředu, lze ho využít jako univerzální nástroj pro predikci finanční tísně ve střední Evropě. Data z více než 550 000 společností ze Střední Evropy byly z databáze Amadeus. Model byl použit k predikci neúspěchu podnikání v roce 2018 na základě finančních proměnných z roku 2017. Model je kombinací metody RobustBoost, CART a k-NN (metoda k-nearest neighbors). Predikční schopnost modelu je 94,25 %. Model vyhovuje více České republice než jiným zemím.

Shetty, Musa a Brédart 2022

Autoři replikují studii od Brédarta (2014), kde predikoval bankrot pomocí metody neuronových sítí a dosáhl predikční schopnosti nad 80 %. Shetty, Musa a Brédart (2022) k předpovědi bankrotu použili čtyři techniky strojového učení. Jsou jimi hluboká neuronová síť, Random forest, Support vector machine a klasifikační algoritmy XGBoost. Model používá tři finanční ukazatele. Data byla od 3 728 belgických firem, které v letech 2002–2012 byly prohlášeny za bankrotní. Přesnost předpovědi bankrotu je 82–83 %. Studie může být zajímavá pro bankéře, kteří chtějí posoudit pravděpodobnost bankrotu firem žádajících o půjčku, aniž by museli počítat mnoho finančních ukazatelů a shromažďovat nefinanční data.

2.23 Zhodnocení současného stavu

Od roku 2015 bylo sestrojeno velké množství bankrotních modelů, založené na různých metodách. Ve výše uvedených podkapitolách je pouze krátký výčet modelů, které byly od roku 2015 zkonstruovány, a to konkrétně 22 modelů s metodou konstrukce vícenásobné diskriminační analýzy nebo logistické regrese. Dále 12 modelů vytvořených se složitějšími metodami, jako umělé neuronové sítě, rozhodovací stromy a další metody.

Autoři stále vytvářejí modely založené na vícenásobné diskriminační analýze, hlavně kvůli lehké konstrukci modelu, použitelnosti a většinou dobré predikční schopnosti. Rozšířilo se i použití logistické analýzy. Pokud autoři vytvářeli modely za pomoci vícenásobné diskriminační analýzy a logistické regrese, lepších výsledků dosáhli za použití logistické regrese.

Konstrukce bankrotních modelů se neustále vyvíjí a do popředí se dostávají i další metody strojového učení, jako jsou neuronové sítě, rozhodovací stromy a metoda k-nearest neighbors. Výhodou je, že metody vytvořené za pomoci těchto metod, často dosahují vyšších a přesnějších výsledků při stanovení predikční schopnosti modelu. Nevýhodou je, že aplikace modelů v praxi je pro podniky náročnější, než při využití modelů založené na diskriminační analýze nebo logistické regresi. Použití je časově náročnější a vyžaduje znalost statistických programů.

Při vytváření modelů, používají autoři data samostatně od malých, středních nebo velkých podniků. Některé modely byly vytvořeny jen z kótovaných společností na burzách. Dalším zaměřením u konstrukce modelů je výběr konkrétní země nebo odvětví. Byly ale vytvořeny i bankrotní modely zaměřené na univerzální použití po celém světě. Lepší predikční schopnosti většinou dosahují modely zaměřené na konkrétní zemi nebo odvětví.

Autoři se snaží nové modely stále zpřesňovat, používají různé finanční ukazatele, přidávají proměnné z konkrétních odvětvích. U globálních modelů přidávají proměnné pro konkrétní stát nebo oblast.

Nejčastěji autoři vytvářejí modely na jeden rok před bankrotem, protože tyto modely mají vyšší predikční schopnost. S přibývajícými roky predikční schopnost modelů klesá.

Predikční schopnost modelu je velmi ovlivněna nejen vybranou metodou konstrukce, ale i vzorkem vybraných podniků a zvolených finančních i nefinančních poměrových ukazatelů.

V současnosti dochází k zapojení makroekonomických proměnných, jako jsou HDP, inflace a nezaměstnanost. Tyto proměnné by mohly zlepšit predikční schopnost modelů.

3 FUNKČNOST VYBRANÝCH MODELŮ V ČR

V této kapitole jsou testovány vybrané bankrotní modely na datech českých podniků ze zpracovatelského průmyslu.

3.1 Data podniků

Z databáze MagnusWeb od společnosti Bisnode byla získána data od českých podniků zpracovatelského průmyslu (sekce C dle klasifikace CZ-NACE). Data byla rozdělena do dvou souborů, na aktivní a bankrotní podniky. S každým vzorkem podniků bylo počítáno samostatně.

Údaje aktivních neboli bonitních podniků byly z roku 2012. Podniky měly obrat nad 300 mil. Kč a nevykazovaly žádné negativní symptomy ve sledovaném období roku. Údaje o bankrotních podnicích byly z roku 2013.

Vybrané modely byly testovány na finančních datech 172 podniků, z toho 115 bylo bonitních a 57 bankrotních.

3.2 Zpracovatelský průmysl dle NACE

Statistickou klasifikaci ekonomických činností NACE používá Evropská unie od roku 1970. V České republice se začala používat od 1. 1. 2008, kdy nahradila stávající klasifikaci OKEČ (Odvětovou klasifikace ekonomických činností). Při zpracování statistik s použitím NACE lze srovnávat údaje v celé Evropské unii i se světovými statistikami. Pro členské státy Evropské unie je použití povinné.

Klasifikace třídí ekonomické činnosti do jednotlivých oblastí a každá oblast má přidělený kód, který se skládá z označení oddílu, skupiny a třídy pro konkrétní ekonomickou činnost. V této práci se vybraný zpracovatelský průmysl nachází v sekci C pod kódy 10 až 33 viz tabulka 5. Zpracovatelský průmysl dle CZ-NACE zahrnuje přeměnu materiálů nebo komponentů na nové produkty. Za výrobu se považuje i podstatná změna, renovace nebo rekonstrukce produktů. (ČSÚ, 2021)

Tabulka 5: Zpracovatelský průmysl dle CZ-NACE

Kód	Zpracovatelský průmysl dle CZ-NACE
10	Výroba potravinářských výrobků
11	Výroba nápojů
12	Výroba tabákových výrobků
13	Výroba textilií
14	Výroba oděvů
15	Výroba usní a souvisejících výrobků
16	Zpracování dřeva, výroba dřevěných, korkových, proutěných a slaměných výr., kromě nábytku
17	Výroba papíru a výrobků z papíru
18	Tisk a rozmnožování nahraných nosičů
19	Výroba koksu a rafinovaných ropných produktů
20	Výroba chemických látek a chemických přípravků
21	Výroba základních farmaceutických výrobků a farmaceutických přípravků
22	Výroba pryžových a plastových výrobků
23	Výroba ostatních nekovových minerálních výrobků
24	Výroba základních kovů, hutní zpracování kovů; slévárenství
25	Výroba kovových konstrukcí a kovodělných výrobků, kromě strojů a zařízení
26	Výroba počítačů, elektronických a optických přístrojů a zařízení
27	Výroba elektrických zařízení
28	Výroba strojů a zařízení j. n
29	Výroba motorových vozidel (kromě motocyklů), přívěsů a návěsů
30	Výroba ostatních dopravních prostředků a zařízení
31	Výroba nábytku
32	Ostatní zpracovatelský průmysl
33	Opravy a instalace strojů a zařízení

Zdroj: upraveno podle (ČSÚ, 2021)

3.3 Vybrané bankrotní modely

Modely byly vybrány z různých zemí, z jiných časových období a s odlišnými poměrovými ukazateli.

Vybrané modely pro zhodnocení finanční tísně jsou:

- Adamowicz a Noga (2021)
- Altman a kol. (2017)
- Ježovita (2015)

Zvolené bankrotní modely budou čerpat data z finančních výkazů společností ve zpracovatelském průmyslu v České republice.

Vybrané bankrotní modely jsou založené na vícenásobné diskriminační analýze. Konstrukce bankrotních modelů se liší počtem a druhem poměrových ukazatelů. Modely Adamowicz a Noga a Ježovita obsahují pět poměrových ukazatelů. Model Altmana a kol. se skládá ze čtyř poměrových ukazatelů.

Následující tabulka zobrazuje přehled poměrových ukazatelů ve vybraných bankrotních modelech. Potřebná data k výpočtu poměrových ukazatelů se nacházejí v účetních výkazech, a to v rozvaze a výkazu zisku a ztráty.

Tabulka 6: Přehled poměrových ukazatelů v bankrotních modelech

Poměrový ukazatel	Bankrotní model		
	Adamowicz a Noga 2021	Altman a kol. 2017	Ježovita 2015
oběžná aktiva / krátkodobé závazky	x		x
celkové tržby/ průměrná roční celková aktiva	x		
vlastní kapitál/ celkový dluh	x	x	
(zisk z provozní činnosti – odpisy) / tržby	x		
provozní náklady / krátkodobé závazky	x		
pracovní kapitál / celková aktiva		x	
nerozdělený zisk / celková aktiva		x	
EBIT / celková aktiva		x	
celkové výnosy / celkové náklady			x
celkové závazky / (nerozdělený zisk + odpisy a amortizace)			x
(hrubý zisk + finanční náklady) / finanční náklady			x
čistý zisk / vlastní kapitál			x

Zdroj: vlastní zpracování

3.4 Aplikace vybraných modelů na data

V následujících podkapitolách jsou testovány tři vybrané modely zvláště na souboru bonitních a bankrotních podniků. U každého modelu je uvedena tabulka správně a chybně zařazených podniků, samostatně pro bonitní a bankrotní podniky.

3.4.1 Adamowicz a Noga (2021)

První testovaný model byl od autorů Adamowicz a Noga. Rovnice a podmínky hodnocení jsou popsány v teoretické části v kapitole 2.18. Původní spolehlivost modelu podle autorů je 89 % jeden rok před bankrotem.

Tabulka 7: Spolehlivost modelu Adamowicz a Noga pro bonitní podniky

Aktivní podniky		
	Absolutní četnost	Relativní četnost
Počet správně určených	115	100 %
Počet chybně určených	0	0 %
Celkový počet podniků	115	100 %

Zdroj: vlastní zpracování

Model správně zařadil všech 115 bonitních podniků.

Tabulka 8: Spolehlivost modelu Adamowicz a Noga pro bankrotní podniky

Bankrotní podniky		
	Absolutní četnost	Relativní četnost
Počet správně určených	6	14,63 %
Počet chybně určených	35	85,37 %
Celkový počet podniků	41	100 %

Zdroj: vlastní zpracování

Model správně zařadil pouze 6 z 41 bankrotujících podniků, odpovídá to spolehlivost určení 14,63 %. Z testování muselo být vyřazeno 16 podniků, z důvodu nulových hodnot u tržeb.

3.4.2 Altman a kol. (2017)

Druhý testovaný model byl od autorů Altman a kol. Rovnice a postup vyhodnocení jsou uvedeny v teoretické části v kapitole 2.11. Původní spolehlivost modelu pro vícenásobnou diskriminační analýzu u křivky ROC je 0,745.

Tabulka 9: Spolehlivost modelu Altman a kol. pro bonitní podniky

Aktivní podniky		
	Absolutní četnost	Relativní četnost
Počet správně určených	110	95,65 %
Počet chybně určených	5	4,35 %
Celkový počet podniků	115	100 %

Zdroj: vlastní zpracování

Spolehlivost modelu pro aktivní podniky 95,65 %. Model správně určil 110 finančně zdravých podniků.

Tabulka 10: Spolehlivost modelu Altman a kol. pro bankrotní podniky

Bankrotní podniky		
	Absolutní četnost	Relativní četnost
Počet správně určených	38	67,86 %
Počet chybně určených	18	32,14 %
Celkový počet podniků	56	100 %

Zdroj: vlastní zpracování

Predikční schopnost pro bankrotní modely byla 67,86 %. Model správně určil 38 bankrotních modelů a 18 podniků chybně označil jako finančně zdravé. Jeden podnik byl z testování vynechán z důvodu chybějících údajů.

3.4.3 Ježovita (2015)

Třetí a poslední testovaný model byl od autorky Ježovita. Rovnice a podmínky hodnocení jsou popsány v teoretické části v kapitole 2.3. Autorka uvádí spolehlivost původního modelu na 95,91 %.

Tabulka 11: Spolehlivost modelu Ježovita pro bonitní podniky

Aktivní podniky		
	Absolutní četnost	Relativní četnost
Počet správně určených	90	88,24 %
Počet chybně určených	12	11,76 %
Celkový počet podniků	102	100 %

Zdroj: vlastní zpracování

Z celkových 115 aktivních podniků bylo vyřazeno 13 podniků, z důvodu nulových hodnot u nákladových úroků. Model ze zbylých 102 podniků správně určil 90 aktivních podniků, což je 88,24 %.

Tabulka 12: Spolehlivost modelu Ježovita pro bankrotní podniky

Bankrotní podniky		
	Absolutní četnost	Relativní četnost
Počet správně určených	28	84,85 %
Počet chybně určených	5	15,15 %
Celkový počet podniků	33	100 %

Zdroj: vlastní zpracování

Z důvodu nulových hodnot u nákladů bylo vyřazeno 24 z 57 bankrotních podniků. Ze zbývajících 33 bankrotních podniků, bylo správně zařazeno 28 podniků. Spolehlivost správně určených podniků je 84,85 %.

4 ZHODNOCENÍ PREDIKČNÍ SCHOPNOSTI VYBRANÝCH MODELŮ


Obsahem této kapitoly je zhodnocení predikční schopnosti vybraných modelů. Nejprve je zde zhodnocena schopnost modelů určit bankrotní a bonitní modely a jejich aritmetický průměr. Dále pro ověření funkčnosti vybraných bankrotních modelů byly vybrány tři kvantifikační metody, které byly vybrány z teoretické části podle složitosti výpočtu. Metody jsou:

- míra správné klasifikace (ACC)
- ROC křivka
- CAP křivka

4.1 Aritmetický průměr správné klasifikace

Obsahem této podkapitoly je grafické porovnání schopnosti modelů samostatně pro bonitní a bankrotní podniky a určení aritmetického průměru správné klasifikace dohromady pro všechny podniky.

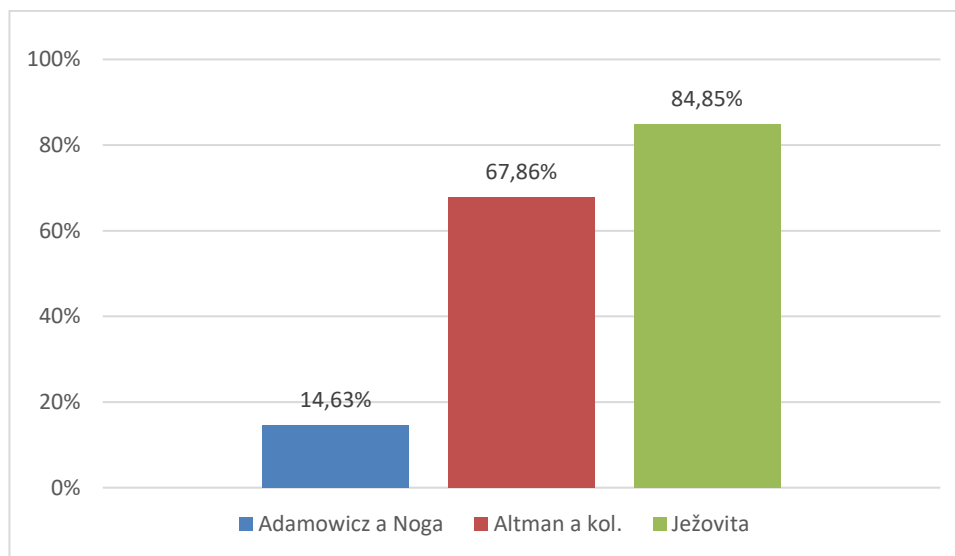
V prvním grafu je zobrazena schopnost modelů určit finančně zdravé podniky. Nejvyšší schopnosti dosáhl model Adamowicz a Noga (100 %). Nejnižší spolehlivost je u modelu Ježovita (88,24 %).



Obrázek 3: Graf spolehlivosti modelů pro bonitní podniky (v %)

Zdroj: vlastní zpracování

V druhém grafu je zobrazena schopnost modelů určit finančně nezdravé podniky. Nejlepšího výsledku dosáhl model Ježovita, který správně určil 84,85 % bankrotních modelů. Nejnižší spolehlivost určení měl model Adamowicz a Noga (14,63 %).




Obrázek 4: Graf spolehlivosti modelů pro bankrotní podniky (v %)

Zdroj: vlastní zpracování

Po porovnání obou grafů, lze konstatovat, že modely Adamowicz a Noga a Altman a kol., které měly vysokou míru správné klasifikace pro bonitní podniky (nad 90 %), vykazovaly nižší predikční schopnost pro bankrotní modely (14,63 % a 67,86 %). Model Ježovita dosáhl podobné spolehlivosti v obou testovaných souborech (88,24 % pro bonitní podniky a 84,85 % pro bankrotní podniky).

Ve třetím grafu je znázorněna spolehlivost pro bankrotní i bonitní podniky aritmetickým průměrem.



Obrázek 5: Graf aritmetického průměru spolehlivosti pro všechny podniky (v %)

Zdroj: vlastní zpracování

Nejlepšího výsledku při výpočtu aritmetického průměru mezi bankrotními a bonitními podniky dosáhl model Ježovita s 86,54 %. Nejnižší výsledek s 57,32 % má model Adamowicz a Noga.

4.2 Míra správné klasifikace (ACC)

První metodou kvantifikace predikčních schopností je míra správné klasifikace. U každého modelu jsou vypočítané hodnoty modelů rozděleny do hodnotící tabulky (kapitola 1.3) a následně je stanovena míra správné klasifikace a celková míra chyby.

4.2.1 Adamowicz a Noga (2021)

V tabulce 13 jsou rozděleny bankrotní i bonitní podniky do hodnotící tabulky pro model Adamowicz a Noga.

Tabulka 13: Hodnotící tabulka Adamowicz a Noga

Aktuální stav	Klasifikace modelem		Celkem
	Bankrotní	Nebankrotní	
Bankrotní	6	35	41
Nebankrotní	0	115	115
Celkem	6	150	156

Zdroj: vlastní zpracování

U modelu je nulová chyba II. druhu, model správně zařadil všechny podniky jako finančně zdravé. Model špatně zařadil 35 z 41 bankrotních podniků jako aktivní (chyba I. druhu).

Tabulka 14: Celková spolehlivost modelu Adamowicz a Noga

Celková spolehlivost	
Míra správné klasifikace	77,56 %
Celková míra chyby	22,44 %
Celkem	100 %

Zdroj: vlastní zpracování

Podle první metody kvantifikace je celková míra správné klasifikace modelu pro bonitní a bankrotní podniky 77,56 % a celková míra chyby je 22,44 %.

4.2.2 Altman a kol. (2017)

Rozřazení podniků do klasifikační tabulky podle Altmana a kol. je v tabulce 15.

Tabulka 15: Hodnotící tabulka Altman a kol.

Aktuální stav	Klasifikace modelem		Celkem
	Bankrotní	Nebankrotní	
Bankrotní	38	18	56
Nebankrotní	5	110	115
Celkem	43	128	171

Zdroj: vlastní zpracování

Model špatně zařadil 18 z 56 bankrotních modelů jako nebankrotní (chyba I. druhu) a u chyby II. druhu nesprávně stanovil pouze 5 pět podniků jako bankrotní z celkových 115 finančně zdravých.

Tabulka 16: Celková spolehlivost modelu Altman a kol.

Celková spolehlivost	
Míra správné klasifikace	86,55 %
Celková míra chyby	13,45 %
Celkem	100 %

Zdroj: vlastní zpracování

U první metody kvantifikace predikční schopnosti modelu vychází míra správné klasifikace 86,55 % pro bankrotní a bonitní podniky. Celková míra chyby vychází na 13,45 %.

4.2.3 Ježovita (2015)

V tabulce 17 je uvedená hodnotící tabulka pro model Ježovita pro bankrotní i bonitní podniky.

Tabulka 17: Hodnotící tabulka Ježovita

Aktuální stav	Klasifikace modelem		Celkem
	Bankrotní	Nebankrotní	
Bankrotní	28	5	33
Nebankrotní	12	90	102
Celkem	40	95	135

Zdroj: vlastní zpracování

Model špatně zařadil 5 bankrotních podniků jako aktivní (chyba I. druhu) a 12 aktivních podniků jako bankrotní (chyba II. druhu). S ohledem na předchozí modely jsou chyby I. a II. druhu vyrovnanější.

Tabulka 18: Celková spolehlivost modelu Ježovita

Celková spolehlivost	
Míra správné klasifikace	87,41 %
Celková míra chyby	12,59 %
Celkem	100 %


Zdroj: vlastní zpracování

První kvantifikační metoda stanovila míru správné klasifikace modelu pro bonitní a bankrotní podniky na 87,41 %. Celková míra chyby vychází na 12,59 %.

Ukázalo se, že modely Adamowicz a Noga a Altman a kol., které měly v kapitole 4.1 vysokou míru klasifikace bonitních podniků a nízkou míru klasifikace bankrotních podniků, měly v hodnotících tabulkách větší chybu I. druhu a menší chybu II. druhu.

4.2.4 Porovnání modelů

Modely jsou porovnány pomocí míry správné klasifikace a celkové míry chyby. V následujícím grafu je vidět celková spolehlivost modelů pro bankrotní a bonitní podniky.



Obrázek 6: Graf míry správné klasifikace (v %)

Zdroj: vlastní zpracování

Nejvyšší spolehlivost dosáhl model Ježovita s 87,41 %. Druhý je model Altman a kol. s 86,55 % mírou správné klasifikace. Nejnižší míru spolehlivosti predikce má s 77,56 % model Adamowicz a Noga.


Největší míru chyby má model Adamowicz a Noga s 22,44 %. Druhý je model Altman a kol. s mírou chyby 13,45 % a nejnižší chybovost má model Ježovita s 12,59 %.

4.3 ROC křivka

Druhou metodou kvantifikace je křivka ROC. Křivka ROC byla zkonstruována pro každý model samostatně v programu IBM SPSS Statistics. Následně byla určena hodnota pod křivka AUC, která byla porovnána s hodnotící stupnicí z kapitoly 1.3.

4.3.1 Adamowicz a Noga (2021)

Pro model Adamowicz a Noga program rozdělil podniky na 114 aktivních, 41 bankrotních a 16 vyřazených. Hodnota pod křivkou AUC vyšla 0,876. Podle hodnotící stupnice z kapitoly 1.3, hodnota spadá do intervalu 0,8 – 0,9, což je dobrý výsledek. Sestavená křivka ROC má následující tvar.




Obrázek 7: Grafické znázornění křivky ROC modelu Adamowicz a Noga

Zdroj: vlastní zpracování

4.3.2 Altman a kol. (2017)

U modelu Altman a kol. rozdělil program podniky na 108 aktivních, 49 bankrotních a 15 podniků s chybějícími údaji. Hodnota pod křivkou AUC vyšla 0,914. Podle hodnotící stupnice z kapitoly 1.3, hodnota spadá do intervalu 0,9 – 1, což je vynikající výsledek. Křivka ROC má následující tvar.




Obrázek 8: Grafické znázornění křivky ROC modelu Altman a kol.

Zdroj: vlastní zpracování

4.3.3 Ježovita (2015)

U modelu Ježovita program rozdělil podniky na 102 aktivních, 33 bankrotních a 37 s chybějícími údaji. Hodnota pod křivkou AUC vyšla 0,939. Podle hodnotící stupnice z kapitoly 1.3, hodnota spadá do intervalu 0,9 – 1, což je vynikající výsledek. Křivka ROC má následující tvar.




Obrázek 9: Grafické znázornění křivky ROC modelu Ježovita

Zdroj: vlastní zpracování

4.3.4 Porovnání modelů

V následujícím grafu jsou uvedeny hodnoty pod křivkou (AUC) pro všechny tři modely.



Obrázek 10: Graf porovnání hodnoty pod křivkou (AUC) u všech modelů

Zdroj: vlastní zpracování

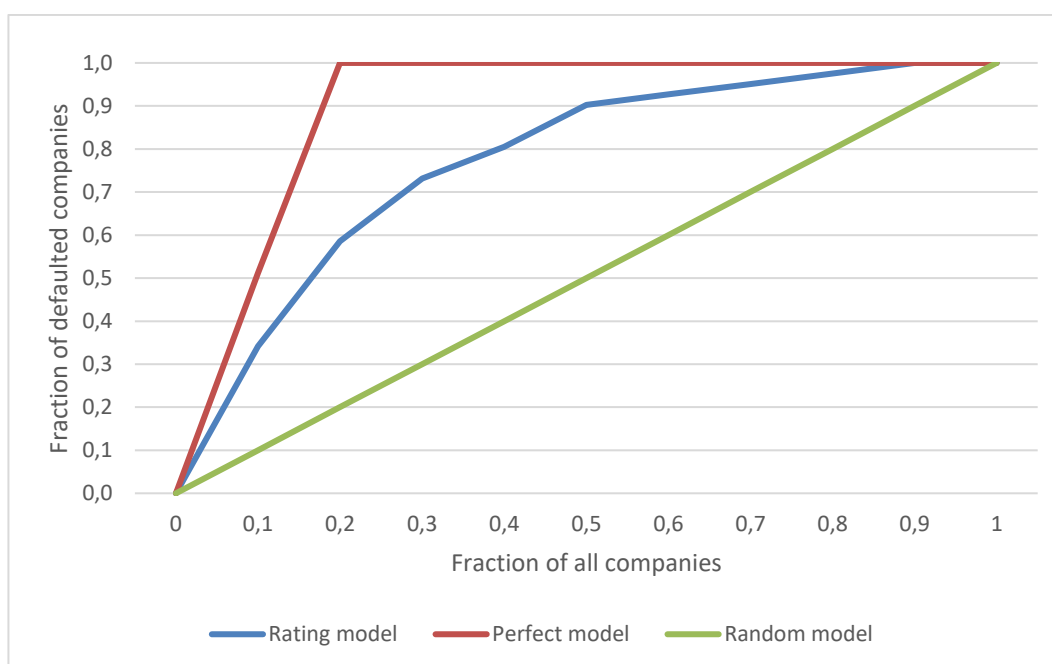
Všechny modely dosáhly alespoň hodnoty 0,7, takže se dají považovat za dobré. Nejvyšší hodnoty 0,939 dosáhl model Ježovita, model má nejvyšší kvantifikační schopnost z vybraných modelů. Druhým modelem s hodnotou 0,914 je Altman a kol. Nejmenší hodnotu a kvantifikační schopnost má model Adamowicz a Noga s 0,876.

4.4 CAP křivka

Třetí vybranou metodou kvantifikace je křivka CAP. Křivka CAP byla vytvořena v MS Excel samostatně pro každý model. V grafu je vždy křivka náhodného, dokonalého a hodnoceného modelu. Dále byla vypočítána hodnota Accuracy ratio (podle kapitoly 1.3).

4.4.1 Adamowicz a Noga (2021)

U modelu Adamowicz a Noga bylo seřazeno 156 podniků podle vypočítaných hodnot od nejrizikovějších po nejlepší. Následně byly hodnoty rovnoměrně rozděleny do 10 skupin. Z vypočítaných hodnot vyšlo Accuracy ratio 0,753, což lze brát jako uspokojivý výsledek. Křivka CAP má následující tvar.

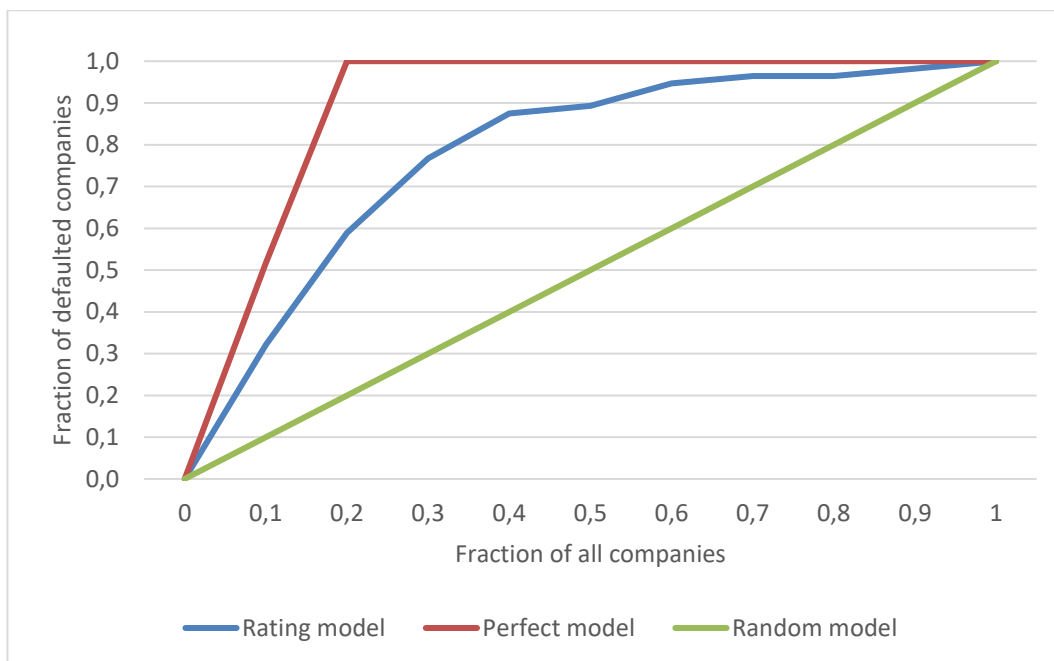


Obrázek 11: Grafické znázornění křivky CAP modelu Adamowicz a Noga

Zdroj: vlastní zpracování

4.4.2 Altman a kol. (2017)

Pro model Altman a kol. bylo od nejrizikovějších po nejlepší seřazeno 171 podniků, podle vypočítaných hodnot. Podniky byly rovnoměrně rozděleny do 10 tříd. Hodnota Accuracy ratio vychází 0,829, což lze brát jako dobrý výsledek. Křivka CAP má následující tvar.

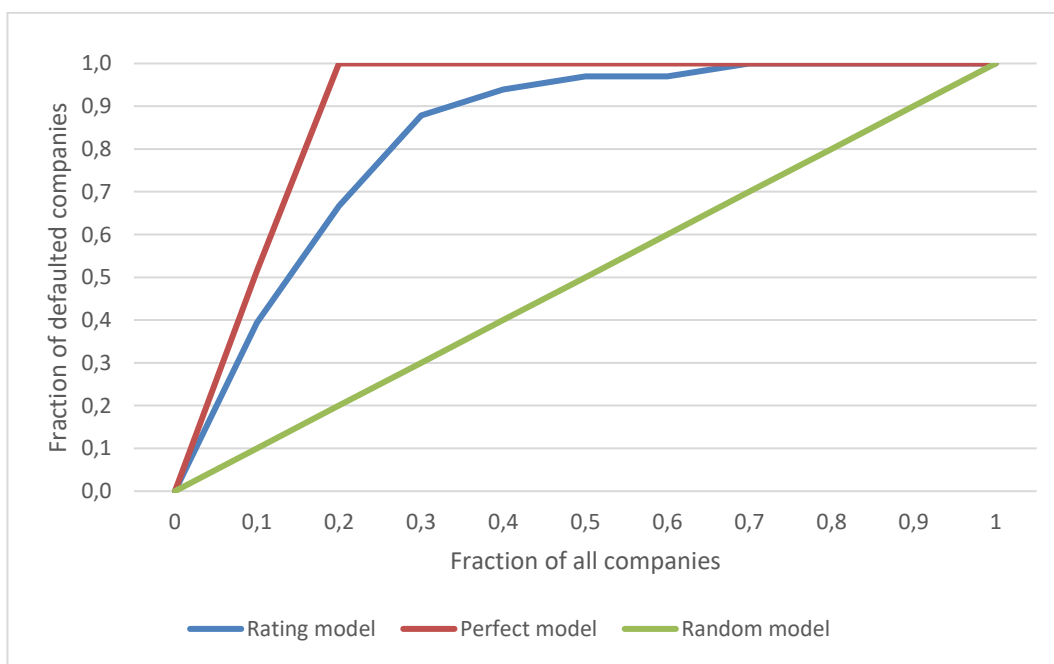


Obrázek 12: Grafické znázornění křivky CAP modelu Altman a kol.

Zdroj: vlastní zpracování

4.4.3 Ježovita (2015)

Pro model Ježovita bylo rozděleno 135 vypočítaných hodnot, od nejrizikovějších po nejlepší podniky. Podniky byly rovnoměrně rozděleny do 10 skupin. Vypočítaná hodnota Accuracy ratio dosáhla dobrého výsledku, a to 0,878. Křivka CAP má následující tvar.

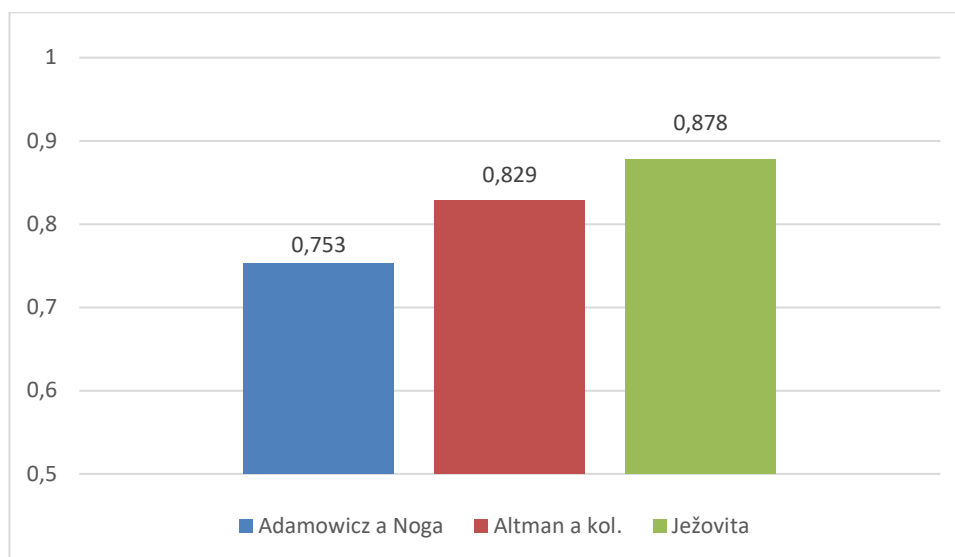


Obrázek 13: Grafické znázornění křivky CAP modelu Ježovita

Zdroj: vlastní zpracování

4.4.4 Porovnání modelů

V následujícím grafu jsou uvedeny hodnoty Accuracy ratio pro všechny tři modely.



Obrázek 14: Graf porovnání hodnoty Accuracy ratio u všech modelů

Zdroj: vlastní zpracování

Všechny modely dosáhly alespoň hodnoty 0,7, takže se dají považovat za dobré. Nejvyšší kvantifikační schopnost má model Ježovita s hodnotou 0,878. Druhým modelem s hodnotou 0,829 je Altman a kol. S nejnižší kvantifikační schopností je model Adamowicz a Noga s hodnotou 0,753.

4.5 Celkové zhodnocení

V následující podkapitole je nejprve porovnána klasifikační schopnost výsledků s původními modely. Následuje zhodnocení všech tří kvantifikačních metod u vybraných modelů.

4.5.1 Porovnání modelů s původní spolehlivostí

Autoři u původních modelů určovali spolehlivost různými metodami. První porovnávanou metodou je míra správné klasifikace. Tuto metodu pro určení původní spolehlivosti použili autoři Adamowicz a Noga a Ježovita.

Tabulka 19: Porovnání vypočítané a původní spolehlivosti

Model	Vypočítaná celková spolehlivost	Původní celková spolehlivost
Adamowicz a Noga 2021	77,56 %	89,00 %
Ježovita 2015	87,41 %	95,91 %

Zdroj: vlastní zpracování

Z tabulky vyplývá, že oba uvedené modely mají v podmínkách České republiky horší spolehlivost než původní modely. Pro model Adamowicz a Noga je rozdíl mezi původní a vypočítanou spolehlivostí větší (11,44 %) než u modelu Ježovita (8,50 %).

Druhou porovnávanou metodou, je hodnota pod křivkou (AUC) pro model Altman a kol.

Tabulka 20: Porovnání vypočítané a původní spolehlivosti hodnoty pod křivkou

Model	Vypočítaná hodnota pod křivkou (AUC)	Původní hodnota pod křivkou (AUC)
Altman a kol. 2017	0,914	0,745

Zdroj: vlastní zpracování

U modelu Altman a kol. vychází lépe vypočítané hodnoty o 0,169 než původní model. Z toho vyplývá, že model má lepší predikční schopnost, pokud je zaměřen na užší vzorek podniků, např. z jednoho státu.

4.5.2 Zhodnocení kvantifikačních metod

V tabulce 21 je uvedené porovnání vybraných kvantifikačních metod pro všechny testované modely.

Tabulka 21: Porovnání vybraných metod kvantifikace

Model	Míra správné klasifikace	Hodnota pod křivkou	Accuracy ratio
Adamowicz a Noga 2021	0,776	0,876	0,753
Altman a kol. 2017	0,865	0,914	0,829
Ježovita 2015	0,874	0,939	0,878

Zdroj: vlastní zpracování

Z uvedených výsledků vyplývá, že nejvyšší predikční schopnost má model Ježovita. Model Ježovita dosáhl nejlepších výsledků ze všech tří kvantifikačních metod. Jako druhý je model Altman a kol. pro všechny metody kvantifikace. Třetí a poslední je model Adamowicz a Noga, který má nejnižší výsledky u všech tří metod kvantifikace.

Z vybraných modelů se jako nejvhodnější bankrotní model pro použití v České republice na podniky ze zpracovatelského průmyslu se ukázal model Ježovita. Druhým použitelným modelem je Altman a kol., který dosáhl nižších výsledků než model Ježovita, ale jeho predikční schopnost vysoká.

ZÁVĚR

Cílem práce bylo zanalyzování celosvětového vývoje v tvorbě bankrotních modelů od roku 2015, zhodnocení současného stavu a ověření funkčnosti vybraných modelů v podmínkách ČR s využitím různých metod pro kvantifikaci jejich predikční schopnosti.

Teoretická část se zaměřila na finanční tíseň a s tím spojené znaky úpadku. Dále byla uvedena problematika bankrotních modelů a některé metody kvantifikace predikčních schopností modelů. Druhá část popisovala vybrané bankrotní modely od roku 2015, konkrétně 22 modelů založených na vícenásobné diskriminační analýze nebo logistické regresi a 12 modelů, které byly vytvořené pomocí umělých neuronových sítí, rozhodovacích stromů a dalšími metodami. Z analýzy vyplynulo, že autoři stále používali ke konstrukci modelů vícenásobnou diskriminační analýzu. U některých modelů dosáhla velmi dobrých predikčních schopností nad 90 %. Vysokých predikčních schopností (nad 95 %) autoři dosahovali při použití modelů s jinou metodou konstrukce, např. logistické regrese, umělé neuronové sítě nebo rozhodovací stromy. Při konstrukci modelů autoři spíše upřednostňovali data podniků z určité země nebo odvětví, před globálními modely. Někteří autoři zvyšovali predikční schopnosti přidáním specifických proměnných pro konkrétních odvětví, stát nebo oblast a makroekonomických proměnných.

V praktické části se testovaly tři vybrané modely na reálných datech podniků ze zpracovatelského průmyslu v České republice. Všechny vybrané modely byly založené na vícenásobné diskriminační analýze. Každý model byl vybrán z jiné země, z jiného roku a s odlišnými poměrovými ukazateli. Testovanými modely byly Adamowicz a Noga (2021), Altman a kol. (2017) a Ježovita (2015). Pro účely této práce byl použit datový soubor z databáze MagnusWeb od společnosti Bisnode, obsahoval finanční data 172 podniků, z toho bylo 115 bonitních (z roku 2012) a 57 bankrotních (z roku 2013).

Vybrané modely testovaly samostatně soubor bonitních a bankrotních podniků. V následující kapitole se zjištěné výsledky porovnávaly. Pro zhodnocení predikční schopnosti vybraných modelů byly použity tři kvantifikační metody, a to konkrétně míra správné klasifikace (ACC), ROC křivka a CAP křivka. Vypočítané spolehlivosti modelů, byly porovnány s původní spolehlivostí modelů.

Z testování vyplynulo, že nejlepší schopnost určit bonitní podniky měl model Adamowicz a Noga (100 %), dále byl Altman a kol. (95,65 %), nejnižší predikční schopnost měl model Ježovita (88,24 %). U bankrotních podniků výsledky modelů vyšly obráceně, a to s nejvyšší predikční schopností model Ježovita (84,85 %), Altman a kol. (67,86 %) a nejnižší schopnost predikce byla u modelu Adamowicz a Noga (14,63 %). Z výsledků vyplynulo, že modely s vysokou mírou správné klasifikace pro bonitní podniky (nad 90 %), zároveň vykazovaly nižší predikční schopnost pro bankrotní modely (pod 70 %). Při porovnání výsledků za použití aritmetického průměru mezi bonitními a bankrotními podniky nejlépe dopadl model Ježovita (86,54 %), dále Altman a kol. (81,75 %) a nejnižší aritmetický průměr měl model Adamowicz a Noga (57,32 %).

Při ověření predikční schopnosti mírou správné klasifikace (ACC) bylo zjištěno, že nejvyšší spolehlivosti dosáhly modely Ježovita (87,41 %) a Altman a kol. (86,55 %). Nižší míru správné klasifikace měl model Adamowicz a Noga (77,56 %). Po sestrojení křivek ROC a vypočítání hodnoty pod křivkou AUC se daly všechny modely považovat za dobré, protože dosáhly alespoň hodnoty 0,7. Nejvyšších hodnot dosáhly modely Ježovita (0,939) a Altman a kol. (0,914), nižší hodnotu měl model Adamowicz a Noga (0,876). Jako poslední byly sestaveny křivky CAP a vypočítáno Accuracy ratio, které opět dosáhlo alespoň hodnoty 0,7. Pořadí modelů bylo Ježovita (0,878), Altman a kol. (0,829) a Adamowicz a Noga (0,753). Z výsledků použitých kvantifikačních metod vyplynulo, že model Ježovita měl nejvyšší predikční schopnost u všech použitých metod.

Zajímavým zjištěním bylo, že nejvyšší predikční schopnosti dosáhl model Ježovita, který byl nejstarší z vybraných modelů, již z roku 2015 a byl vytvořen z dat od chorvatských společností, které se odlišovaly od českých podniků. Model správně určil podobně bonitní (88,24 %) i bankrotní (84,85 %) podniky. Druhé nejvyšší predikční schopnosti dosáhl model Altman a kol. z roku 2017, který autoři sestrojili na datech 31 evropských zemí a 3 zemích mimo Evropu z různých odvětví. Model určil vysoké množství bonitních podniků (95,65 %), slabší bylo zařazení bankrotních podniků (67,86 %). Z vybraných modelů nejnovějším byl model Adamowicz a Noga z roku 2021 z dat od polských podniků dřevozpracujícího průmyslu, který ale dosáhl nejnižších výsledků u všech predikčních modelů. I když tento model správně zařadil všechny bonitní podniky, tak bankrotních podniků zařadil jen velmi málo (14,63 %).

Z vybraných modelů lze pro podniky ze zpracovatelského průmyslu v České republice doporučit modely Ježovita a Altman a kol.

POUŽITÁ LITERATURA

- [1] ABID, Ilyes, Rim AYADI, Khaled GUESMI a Farid MKAOUAR. A new approach to deal with variable selection in neural networks: an application to bankruptcy prediction. *Annals of Operations Research* [online]. 2021 [cit. 2022-02-09]. ISSN 0254-5330. Dostupné z: doi:10.1007/s10479-021-04236-4
- [2] ADAMKO, Peter, Tomáš KLIEŠTIK a Mária KOVÁČOVÁ. AN GLM MODEL FOR PREDICTION OF CRISIS IN SLOVAK COMPANIES. In: *How to Cope With Disrupted Times* [online]. 2018, s. 223-228 [cit. 2021-11-14]. Dostupné z: doi:10.31410/EMAN.2018.223
- [3] ADAMOWICZ, Krzysztof a Tomasz NOGA. Identification of financial ratios applicable in the construction of a prediction model for bankruptcy of wood industry enterprises. *Folia Forestalia Polonica* [online]. 2018, 60(1), 61-72 [cit. 2021-10-20]. ISSN 2199-5907. Dostupné z: doi:10.2478/ffp-2018-0006
- [4] ALAMINOS, David, Agustín DEL CASTILLO, Manuel Ángel FERNÁNDEZ a Giovanni PONTI. A Global Model for Bankruptcy Prediction. *PLOS ONE* [online]. 2016, 11(11) [cit. 2022-02-08]. ISSN 1932-6203. Dostupné z: doi:10.1371/journal.pone.0166693
- [5] ALMAMY, Jeehan, John ASTON a Leonard N. NGWA. An evaluation of Altman's Z-score using cash flow ratio to predict corporate failure amid the recent financial crisis: Evidence from the UK. *Journal of Corporate Finance* [online]. 2016, 36, 278-285 [cit. 2022-02-17]. ISSN 09291199. Dostupné z: doi:10.1016/j.jcorpfin.2015.12.009
- [6] ALTMAN, Edward I. Corporate financial distress: a complete guide to predicting, avoiding, and dealing with bankruptcy. John Wiley, 1983.
- [7] ALTMAN, Edward I. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance* [online]. 1968, 23(4), 589-609 [cit. 2022-02-17]. ISSN 00221082. Dostupné z: doi:10.2307/2978933
- [8] ALTMAN, Edward I., Edith HOTCHKISS a Wei WANG. Corporate Financial Distress, Restructuring, and Bankruptcy: Analyze Leveraged Finance, Distressed Debt, and Bankruptcy. 4th ed. Hoboken: John Wiley, c2019, 349p. ISBN 978-1-119-48181-2.
- [9] ALTMAN, Edward I., Małgorzata IWANICZ-DROZDOWSKA, Erkki K. LAITINEN a Arto SUVAS. Financial Distress Prediction in an International Context: A Review and

- Empirical Analysis of Altman's Z- Score Model. *Journal of International Financial Management & Accounting* [online]. 2017, 28(2), 131-171 [cit. 2022-02-17]. ISSN 09541314. Dostupné z: doi:10.1111/jifm.12053
- [10] BRÉDART, Xavier, Eric SÉVERIN a David VEGANZONES. Human resources and corporate failure prediction modeling: Evidence from Belgium. *Journal of Forecasting* [online]. 2021, 40(7), 1325-1341 [cit. 2022-02-08]. ISSN 0277-6693. Dostupné z: doi:10.1002/for.2770
- [11] BUTKUS, Mindaugas, Sigita ŽAKARĖ a Diana CIBULSKIENĖ. Bankroto diagnostikos modelis ir jo pritaikymas bankroto tikimybei Lietuvos įmonėse prognozuoti. *Applied Economics: Systematic Research* [online]. 2014, 8.1(8.1), 111-132 [cit. 2021-12-16]. ISSN 18227996. Dostupné z: doi:10.7220/AESR.1822.7996.2014.8.1.7
- [12] CINDIK, Zeynep a Ismail H. ARMUTLULU. A revision of Altman Z-Score model and a comparative analysis of Turkish companies' financial distress prediction. *National Accounting Review* [online]. 2021, 3(2), 237-255 [cit. 2022-02-05]. ISSN 2689-3010. Dostupné z: doi:10.3934/NAR.2021012
- [13] ČESKÝ STATISTICKÝ ÚŘAD, 2021. Klasifikace ekonomických činností CZ-NACE [online]. [cit. 2022-03-17]. Dostupné z: https://www.czso.cz/csu/czso/klasifikace_ekonomickyh_cinnosti_cz_nace
- [14] DURICA, M. a P. ADAMKO. Verification of MDA Bankruptcy Prediction Models for Enterprises in Slovak Republic. In *Proceedings of the 10th International Days of Statistics and Economics*. Prague, Czech Republic: Melandrium, 2016, 400-407. ISSN 978-80-87990-10-0.
- [15] DURICA, M., J. FRNDA a L. SVABOVA. Decision tree based model of business failure prediction for Polish companies. *Oeconomia Copernicana* [online]. 2019, 10(3), 453-469 [cit. 2021-12-12]. Dostupné z: doi:10.24136/oc.2019.022
- [16] Engelmann, B., E. Hayden a D. Tasche. 2003. Measuring the Discriminative Power of Rating Systems. Deutsche Bundesbank, Discussion paper, Series 2: Banking and Financial Supervision, (1), 1-24. ISBN 3-935821-67-0
- [17] FAWCETT, Tom. An introduction to ROC analysis. *Pattern Recognition Letters* [online]. 2006, 27(8), 861-874 [cit. 2022-02-20]. ISSN 01678655. Dostupné z: doi:10.1016/j.patrec.2005.10.010

- [18] GIRIŪNIENE, Gintare, Lukas GIRIŪNAS, Mangirdas MORKUNAS a Laura BRUCAITE. A Comparison on Leading Methodologies for Bankruptcy Prediction: The Case of the Construction Sector in Lithuania. *Economies* [online]. 2019, 7(3) [cit. 2021-12-16]. ISSN 2227-7099. Dostupné z: doi:10.3390/economies7030082
- [19] HERMAN, Sergiusz, 2017, Industry specifics of joint-stock companies in Poland and their bankruptcy prediction. In: PAPIEŻ, Monika and ŚMIECH, Sławomir, *Proceedings of the 11th Professor Aleksander Zelias International Conference on Modelling and Forecasting of Socio-Economic Phenomena*. Foundation of the Cracow University of Economics. 2017. p. 93–102. Proceedings of the 11th Professor Aleksander Zelias International Conference on Modelling and Forecasting of Socio-Economic Phenomena.
- [20] HORAK, Jakub, Jaromir VRBKA a Petr SULER. Support Vector Machine Methods and Artificial Neural Networks Used for the Development of Bankruptcy Prediction Models and their Comparison. *Journal of Risk and Financial Management* [online]. 2020, 13(3) [cit. 2022-02-01]. ISSN 1911-8074. Dostupné z: doi:10.3390/jrfm13030060
- [21] HORVÁTHOVÁ, Jarmila, Martina MOKRIŠOVÁ a Igor PETRUŠKA. Selected Methods of Predicting Financial Health of Companies: Neural Networks Versus Discriminant Analysis. *Information* [online]. 2021, 12(12) [cit. 2022-02-01]. ISSN 2078-2489. Dostupné z: doi:10.3390/info12120505
- [22] CHAUDHURI, Arindam a Soumya K. GHOSH. Bankruptcy Prediction through Soft Computing based Deep Learning Technique. Singapore: Springer Nature, c2017, 102p. ISBN 978-981-10-6683-2.
- [23] Informace GFŘ č.j. 101/13-121002-506729 ve znění Dodatku č. 1, č.j. 55366/13/7001–21002-012287, Dodatku č. 2, č.j. 38461/14/7001-21002-012287, Dodatku č. 3, č.j. 74861/17/7100-20118-012287 a Dodatku č. 4, č.j. 137801/17/7100-20118-012287. Finanční správa [online]. 19.12.2017 [cit. 2022-02-10]. Dostupné z: https://www.financnisprava.cz/assets/cs/prilohy/d-seznam-dani/2017_Info_NESPP-vezneni-dodatku4.pdf.
- [24] JENČOVÁ, Sylvia, Róbert ŠTEFKO a Petra VAŠANIČOVÁ. Scoring Model of the Financial Health of the Electrical Engineering Industry's Non-Financial Corporations. *Energies* [online]. 2020, 13(17) [cit. 2021-12-13]. ISSN 1996-1073. Dostupné z: doi:10.3390/en13174364

- [25] JEŽOVITA, A. Designing the model for evaluating financial quality of business operations – evidence from Croatia. *Management: Journal of Contemporary Management* [online]. 2015, 20(1), 101-129 [cit. 2022-02-09].
- [26] KALOUDA, František. Finanční analýza a řízení podniku. 3. rozšířené vydání. Plzeň: Vydavatelství a nakladatelství Aleš Čeněk, 2017. 328s. ISBN 978-80-7380-646-0.
- [27] KLIESTIK, T., J. VRBKA a Z. ROWLAND. Bankruptcy prediction in Visegrad group countries using multiple discriminant analysis. *Equilibrium. Quarterly Journal of Economics and Economic Policy* [online]. 2018, 13(3), 569-593 [cit. 2022-02-02]. Dostupné z: doi:10.24136/eq.2018.028
- [28] KNÁPKOVÁ, Adriana, Drahomíra PAVELKOVÁ, Daniel REMEŠ a Karel ŠTEKER. Finanční analýza: komplexní průvodce s příklady. 3., kompletně aktualizované vydání. Praha: Grada Publishing, 2017. 228s. Prosperita firmy. ISBN 978-80-271-0563-2.
- [29] KOROL, Tomasz. Dynamic Bankruptcy Prediction Models for European Enterprises. *Journal of Risk and Financial Management* [online]. 2019, 12(4) [cit. 2021-10-3]. ISSN 1911-8074. Dostupné z: doi:10.3390/jrfm12040185
- [30] Les symptômes de la faillite: le cas de la Belgique. *L'Actualité économique* [online]. 2014, 90(2), 105-119 [cit. 2022-02-08]. Dostupné z: doi:10.7202/1027974ar
- [31] MEHDI, T. et al. 2011. Kernel smoothing for ROC curve and estimation for thyroid stimulating hormone. *International Journal of Public Health Research*, 2011, 239-242.
- [32] MIHALOVIČ, M. Performance Comparison of Multiple Discriminant Analysis and Logit Models in Bankruptcy Prediction. *Economics and Sociology* [online]. 2016, 9(4), 101-118 [cit. 2022-02-03]. Dostupné z: doi:10.14254/2071-789X.2016/9-4/6
- [33] NĚMEC, Daniel a Michal PAVLÍK. Predicting insolvency risk of the Czech companies. In Marian Reiff, Pavel Gežík. *Proceedings of the International Scientific Conference Quantitative Methods in Economics (Multiple Criteria Decision Making XVIII)*. Bratislava: University of Economics, 2016. s. 258-263. ISBN 978-80-972328-0-1.
- [34] NOGA, Tomasz a Krzysztof ADAMOWICZ. Forecasting bankruptcy in the wood industry. *European Journal of Wood and Wood Products* [online]. 2021, 79(3), 735-743 [cit. 2021-10-20]. ISSN 0018-3768. Dostupné z: doi:10.1007/s00107-020-01620-y
- [35] OGACHI, Daniel, Richard NDEGE, Peter GATURU a Zeman ZOLTAN. Corporate Bankruptcy Prediction Model, a Special Focus on Listed Companies in Kenya. *Journal*

- of Risk and Financial Management* [online]. 2020, 13(3) [cit. 2021-12-16]. ISSN 1911-8074. Dostupné z: doi:10.3390/jrfm13030047
- [36] OUENNICHE, Jamal, Mohammad M. MOUSAVI, Bing XU a Kaoru TONE. RANKING OF BANKRUPTCY PREDICTION MODELS UNDER MULTIPLE CRITERIA. TONE, Kaoru, ed. *Advances in DEA Theory and Applications* [online]. Chichester, UK: John Wiley, 2017, 2017-05-06, s. 357-380 [cit. 2022-02-18]. ISBN 9781118946688. Dostupné z: doi:10.1002/9781118946688.ch24
- [37] PAVLICKO, Michal, Marek DURICA a Jaroslav MAZANEC. Ensemble Model of the Financial Distress Prediction in Visegrad Group Countries. *Mathematics* [online]. 2021, 9(16) [cit. 2021-11-14]. ISSN 2227-7390. Dostupné z: doi:10.3390/math9161886
- [38] PÍŠA, Petr Ing. Způsobení úpadku. *Zivnostik.cz* [online]. Dashöfer Holding, © 1997–2022, 25.4.2019 [cit. 2022-02-07]. Dostupné z: https://www.zivnostnik.cz/33/zpusobeni-upadku-uniqueidmRRWSbk196FNf8-jVUh4EngbtKSxp_9tLq0ynWXR2hw/
- [39] PRUSAK, Błażej. Review of Research into Enterprise Bankruptcy Prediction in Selected Central and Eastern European Countries. *International Journal of Financial Studies* [online]. 2018, 6(3) [cit. 2021-9-29]. ISSN 2227-7072. Dostupné z: doi:10.3390/ijfs6030060
- [40] RŮČKOVÁ, Petra. Finanční analýza: metody, ukazatele, využití v praxi. 6. aktualizované vydání. Praha: Grada Publishing, 2019. 152s. Finanční řízení. ISBN 978-80-271-2028-4.
- [41] SFAKIANAKIS, Evangelos. Bankruptcy prediction model for listed companies in Greece. *Investment Management and Financial Innovations* [online]. 2021, 18(2), 166-180 [cit. 2022-02-08]. ISSN 18104967. Dostupné z: doi:10.21511/imfi.18(2).2021.14
- [42] SHETTY, Shekar, Mohamed MUSA a Xavier BRÉDART. Bankruptcy Prediction Using Machine Learning Techniques. *Journal of Risk and Financial Management* [online]. 2022, 15(1) [cit. 2022-02-08]. ISSN 1911-8074. Dostupné z: doi:10.3390/jrfm15010035
- [43] SHIRINKINA, Elena V. a Laisan A. VALIULLINA. Formalization of the model of the enterprise insolvency risk prediction. *Actual Problems of Economics and Law* [online]. 2015, 09(4), 169-180 [cit. 2022-02-09]. ISSN 1993047X. Dostupné z: doi:10.21202/1993-047X.09.2015.4.169-180

- [44] SCHELLEOVÁ, Ilona. *Exekuce*. Ostrava: Key Publishing, 2008. Právo (Key Publishing). ISBN ISBN978-80-87071-91-5.
- [45] SCHÖNFELD, Jaroslav. *Transformace a restrukturalizace podniku*. V Praze: C.H. Beck, 2018. Beckova edice ekonomie. ISBN 978-80-7400-690-6.
- [46] SINGH, Bhanu Pratap a Alok Kumar MISHRA. Re-estimation and comparisons of alternative accounting based bankruptcy prediction models for Indian companies. *Financial Innovation* [online]. 2016, 2(1) [cit. 2021-12-15]. ISSN 2199-4730. Dostupné z: doi:10.1186/s40854-016-0026-9
- [47] SVABOVA, Lucia, Lucia MICHALKOVA, Marek DURICA a Elvira NICA. Business Failure Prediction for Slovak Small and Medium-Sized Companies. *Sustainability* [online]. 2020, 12(11) [cit. 2021-12-13]. ISSN 2071-1050. Dostupné z: doi:10.3390/su12114572
- [48] SVABOVA, Lucia, Marek DURICA a Ivana PODHORSKA. Prediction of Default of Small Companies in the Slovak Republic. *Economics and Culture* [online]. 2018, 15(1), 88-95 [cit. 2021-12-15]. ISSN 2256-0173. Dostupné z: doi:10.2478/jec-2018-0010
- [49] SYNEK, Miloslav. *Manažerská ekonomika*. 5., aktualiz. a dopl. vyd. Praha: Grada, 2011. Expert (Grada). ISBN 978-80-247-3494-1.
- [50] ŠLEFENDORFAS, Gediminas. Bankruptcy prediction model for private limited companies of Lithuania. *Ekonomika* [online]. 2016, 95(1), 134-152 [cit. 2021-12-16]. ISSN 2424-6166. Dostupné z: doi:10.15388/Ekon.2016.1.9910
- [51] VODA, Alina Daniela, Gabriela DOBROTĂ, Diana Mihaela ȚÎRCĂ, Dănuț Dumitru DUMITRAȘCU a Dan DOBROTĂ. CORPORATE BANKRUPTCY AND INSOLVENCY PREDICTION MODEL. Technological and Economic Development of Economy [online]. 2021, 27(5), 1039-1056 [cit. 2021-10-15]. ISSN 2029-4913. Dostupné z: doi:10.3846/tede.2021.15106
- [52] VOCHOZKA, Marek a Petr MULAČ. *Podniková ekonomika*. Praha: Grada, 2012. Finanční řízení. ISBN 978-80-247-4372-1.
- [53] VOCHOZKA, Marek, Jarmila STRAKOVÁ a Jan VÁCHAL. Model to Predict Survival of Transportation and Shipping Companies. *Naše more* [online]. 2015, 62(SI), 109-113 [cit. 2021-11-12]. ISSN 04696255. Dostupné z: doi:10.17818/NM/2015/SI4
- [54] VOCHOZKA, Marek, Jaromir VRBKA a Petr SULER. Bankruptcy or Success? The Effective Prediction of a Company's Financial Development Using

LSTM. *Sustainability* [online]. 2020, 12(18) [cit. 2021-11-08]. ISSN 2071-1050. Dostupné z: doi:10.3390/su12187529

- [55] VOCHOZKA, Marek. *Finance podniku: komplexní pojetí*. Praha: Grada Publishing, 2021. Finance. ISBN 978-80-271-3267-6.
- [56] VOCHOZKA, Marek. *Metody komplexního hodnocení podniku*. 2. aktualizované vydání. Praha: Grada Publishing, 2020. 479s. Finance. ISBN 978-80-271-1701-7.
- [57] WHITAKER, Richard B. The early stages of financial distress. *Journal of Economics and Finance* [online]. 1999, 23(2), 123-132 [cit. 2022-02-07]. ISSN 1055-0925. Dostupné z: doi:10.1007/BF02745946
- [58] Zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení (insolvenční zákon), ve znění pozdějších předpisů.
- [59] Zákon č. 235/2004 Sb., o dani z přidané hodnoty, ve znění pozdějších předpisů.
- [60] ZHAO, Dong, Chunyu HUANG, Yan WEI, Fanhua YU, Mingjing WANG a Huiling CHEN. An Effective Computational Model for Bankruptcy Prediction Using Kernel Extreme Learning Machine Approach. *Computational Economics* [online]. 2017, 49(2), 325-341 [cit. 2021-10-22]. ISSN 0927-7099. Dostupné z: doi:10.1007/s10614-016-9562-7